

**VŠB – Technická univerzita Ostrava**  
**Fakulta elektrotechniky a informatiky**

## **Diplomová práce**

2018

Bc. Kovářová Veronika

**VŠB – Technická univerzita Ostrava**  
**Fakulta elektrotechniky a informatiky**  
**Katedra kybernetiky a biomedicínského inženýrství**

**Automatická analýza, modelování a časová  
evaluace retinálních lézí**  
**Automatic analysis, Modeling and Temporal  
Evaluation of Retinal Lesions**

VŠB - Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra kybernetiky a biomedicínského inženýrství

## Zadání diplomové práce

Student: **Bc. Veronika Kovářová**  
Studijní program: N2649 Elektrotechnika  
Studijní obor: 3901T009 Biomedicínské inženýrství  
Téma: **Automatická analýza, modelování a časová evaluace retinálních lézí**  
**Automatic Analysis, Modeling and Temporal Evaluation**  
**of Retinal Lesions**  
Jazyk vypracování: čeština

### Zásady pro vypracování:

1. Stručné teoretické shrnutí problematiky retinopatie nedonošených, možnosti její diagnostiky a léčby s důrazem na popis technických aspektů zobrazovacího systému RetCam 3. generace.
2. Teoretický přehled možných retinálních lézí u dětí a jejich stručný klinický popis.
3. Rešerše obrazové analýzy retinálních lézí ze sítnicových obrazových záznamů.
4. Návrh algoritmu registrace obrazu s cílem unifikace polohy retinálních lézí.
5. Návrh plně automatizovaného segmentačního algoritmu pro extrakci a modelování retinálních lézí.
6. Návrh algoritmu pro diferenciaci jednotlivých lézí v segmentačním modelu (hodnocení v čase).
7. Analýza geometrických parametrů retinálních lézí v čase vůči velikosti terče zrakového nervu.
8. Testování a hodnocení navržených algoritmů na reálných klinických datech.

### Seznam doporučené odborné literatury:

- [1] DESERNO, Thomas M. *Biomedical image processing*. Heidelberg: Springer, c2011. ISBN 978-3-642-15816-2.
- [2] EL-BAZ, Ayman S., Xiaoyi JIANG a Jasjit S. SURI. *Biomedical image segmentation: advances and trends*. Boca Raton: CRC Press, Taylor & Francis Group, 2017. ISBN 978-1482258554.
- [3] BROWNING, DAVID J. (ed.) *Diabetic retinopathy evidence-based management*. New York: Springer, 2010. ISBN 978-0387859002.
- [4] WU, Gloria. *Diabetic retinopathy: the essentials*. Philadelphia: Wolters Kluwer/Lippincott Williams & Wilkins, c2010. ISBN 978-1605476629.



Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

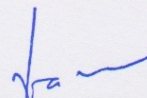
Vedoucí diplomové práce: **doc. Ing. Marek Penhaker, Ph.D.**

Datum zadání: 01.09.2017

Datum odevzdání: 30.04.2018



doc. Ing. Jiří Koziorek, Ph.D.  
vedoucí katedry



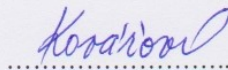
prof. Ing. Pavel Brandštetter, CSc.  
děkan fakulty

## Prohlášení a poděkování studenta

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.

Ráda bych touto cestou poděkovala vedoucímu diplomové práce doc. Ing. Marku Penhakerovi, Ph.D. za odborné vedení, cenné rady a připomínky při tvorbě této práce. Dále také panu MUDr. Juraji Timkovičovi, Ph.D. za spolupráci a poskytnutí dat pro tvorbu diplomové práce.

Dne: 30.4.2018



Veronika Kovářová

## **Abstrakt**

Hlavním tématem diplomové práce je analýza a modelování retinálních lézí z klinických obrazových záznamů ze systému RetCam3. V rámci práce byl navrhnout segmentační algoritmus na bázi časově iteračních deformovatelných křivek, které jsou reprezentovány modelem aktivních kontur. Aktivní kontury modifikují své geometrické vlastnosti v průběhu segmentačního procesu, a tím postupně aproximují oblast manifestace retinálních lézí. Výsledkem je binární matematický model, reflektující geometrické parametry retinálních lézí. Důležitou procedurou navrhovaného modelu je diferenciací jednotlivých lézí. Tato klasifikační procedura umožňuje separovat jednotlivé retinální léze s cílem označení a sledování partikulární léze. Model umožňuje extrakci geometrických parametrů individuálních lézí s cílem objektivizace manifestace léze vůči optickému disku. Modelování retinálních lézí bylo testováno na rozsáhlém datasetu, obsahujícím 1015 záznamů.

## **Klíčová slova**

Retinopatie nedonošených, automatická analýza, modelace, sítnice, sítnicové léze, zpracování obrazu, RetCam3, MATLAB

## **Abstract**

The main theme of this diploma thesis is the analysis and modeling of retinal lesions from clinical images from the RetCam3 system. In the thesis, a segmentation algorithm was designed based on time-iterative deformable curves, which are represented by a model of active contours. Active contours modify their geometric properties during the segmentation process, thereby gradually approximating the area of manifestation of retinal lesions. The result is a binary mathematical model reflecting the geometric parameters of retinal lesions. An important procedure of the proposed model is the differentiation of individual lesions. This classification procedure makes it possible to separate individual retinal lesions in order to identify and monitor a particular lesion. The model allows the extraction of geometric parameters of individual lesions in order to objectivize the manifestation of the lesion against the optical disk. Modeling of retinal lesions was tested on a large dataset containing 1015 records.

## **Key words**

Retinopathy of prematurity, automatic analysis, modelation, retina, retinal lesions, image processing, RetCam3, MATLAB

## Obsah

Seznam použitých symbolů a zkratk .....	8
Seznam ilustrací .....	9
Seznam tabulek.....	13
1 Úvod.....	14
2 Anatomie oka .....	15
2.1 Stavba oka .....	15
2.2 Stavba sítnice.....	16
2.2.1 Cévní zásobení sítnice .....	17
3 Retinopatie nedonošených.....	18
3.1 Klasifikace retinopatie.....	18
3.1.1 Lokalizace změn na sítnici.....	18
3.1.2 Hodnocení závažnosti onemocnění .....	19
3.2 Screening a diagnostika.....	19
3.2.1 RetCam 3 .....	20
3.2.2 Nepřímá oftalmoskopie .....	21
3.3 Léčba ROP .....	21
3.3.1 Kryoterapie sítnice.....	22
3.3.2 Laserová fotokoagulace sítnice.....	22
4 Retinální léze.....	23
5 Rešerše problematiky detekce sítnicových lézí.....	24
5.1 Detekce krvácivých lézí na snímcích očního pozadí pomocí Frangiho filtrů .....	24
5.2 Automatická detekce krvácivých lézí v přítomnosti krevních cév morfologickými operacemi.....	26
5.3 Detekce abnormalit na fundus snímcích sítnice .....	29
5.4 Nový přístup v detekci krvácivých retinálních lézí pomocí funkce Superpixel multi-features clasification v barevných snímcích očního pozadí.....	32
5.5 Detekce retinálních lézí za použití morfologické operace a kvalifikace pixelů .....	36
5.6 Detekce mikroaneurysmat na retinálních snímcích morfologickým přístupem .....	39
5.7 Automatická detekce diabetické retinopatie na digitálních retinálních snímcích: nástroj pro screening diabetické retinopatie .....	43
6 Analýza patientských dat.....	44

7	Teoretický návrh algoritmu pro analýzu retinálních lézí .....	46
8	Předzpracování obrazu .....	47
8.1	Výběr vhodné chrominační složky retinálního snímku .....	48
8.2	Ekvalizace histogramu .....	49
8.3	Jasové transformace .....	50
8.4	Mediánová filtrace .....	51
9	Segmentace obrazu .....	52
9.1	Aktivní kontury .....	52
9.1.1	Numerický postup implementace .....	53
9.1.2	Inicializační kontura a její umístění .....	54
9.2	Binarizace .....	55
10	Diferenciace retinálních lézí .....	58
10.1	Image labeling .....	58
11	Analýza geometrických parametrů retinálních lézí .....	59
12	Návrh algoritmu registrace obrazu .....	60
12.1	Registrace obrazu .....	60
12.2	Registrace retinálních obrazů .....	61
13	Testování a hodnocení parametrů algoritmu na reálných patientských datech .....	62
13.1	Vliv předzpracování obrazu na následnou detekci retinálních lézí .....	62
13.2	Parametry aktivních kontur .....	63
13.2.1	Počet iterací .....	63
13.2.2	Velikost inicializační kružnice .....	64
13.2.3	Délka časového kroku .....	65
13.3	Závislost velikosti obrazu na kvalitě detekce .....	66
13.3.1	Imresize .....	66
13.3.2	RoI .....	69
14	Výsledky testování algoritmu na reálných patientských datech .....	71
14.1	Modelace retinální léze a diferenciace .....	71
14.2	Extrakce geometrických parametrů retinálních lézí .....	78
	Závěr .....	82
	Seznam použité literatury .....	83
	Seznam Příloh .....	86



## SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

a. – artérie  
lat. – latinsky  
OD – optický disk  
PD – Papilla diameter  
RoI – oblast zájmu (region of interest)  
ROP – retinopatie nedonošených  
tzv. – takzvaný

## SEZNAM ILUSTRACÍ

Obrázek 1: Stavba oka [15] .....	15
Obrázek 2: Stavba sítnice [14] .....	16
Obrázek 3: Cévy sítnice [16] .....	17
Obrázek 4: Cévní zásobenění oka [17] .....	17
Obrázek 5: Schéma hodnocení lokalizace a rozsahu změn na sítnici [18] .....	18
Obrázek 6: Stádia retinopatie nedonošených [19] .....	19
Obrázek 7: Přístroj RetCam3 [20] .....	20
Obrázek 8: Nepřímý oftalmoskop [21] .....	21
Obrázek 9: Příklad řidšího výskytu retinálních lézí .....	23
Obrázek 10: Hustší výskyt retinálních lézí .....	23
Obrázek 11: Místo nejostřejšího vidění – Makula [16] .....	23
Obrázek 12: Výstupy po aplikaci filtru na jednotlivé léze. (a) je pro MA, (b) je pro H .....	25
Obrázek 13: Vstupní nativní snímek .....	26
Obrázek 14: SVM klasifikace .....	27
Obrázek 15: Blokové schéma průběhu zpracování obrazu popisované metody .....	28
Obrázek 16: Výsledek celého procesu – detekované krvácivé léze .....	28
Obrázek 17: Prostorová kalibrace .....	29
Obrázek 18: DSF zobrazeno na čtyřech kandidátech získaných ze snímku. S1 a S4 odpovídají krevním cévám, S2 a S3 .....	31
Obrázek 19: Blokové schéma metody .....	31
Obrázek 20: Blokové schéma jednotlivých operací detekce .....	32
Obrázek 21: Příklady použití metody CLAHE na dvou retinálních snímcích. Snímky (a) a (b) jsou nativní obrazy, (b) a (c) vyobrazují upravené snímky metodou CLAHE .....	32
Obrázek 22: Segmentace metodou SLIC. (a) předzpracovaný snímek, (b) detailní zobrazení léze, (c-e) superpixelová segmentace s velikostí oblastí 10, 30 a 50 pixelů .....	33
Obrázek 23: (a) originální monochromatický snímek $I_{green}$ , (b-f) vylepšené obrazy zelené chrominační složky, zvýrazněné struktury s nízkou intenzitou $I_{dark\_enhanced}$ , operace morfologického uzavírání $I_{close}$ , barevně sjednocený snímek $I_{hue\_enhanced}$ a $M$ komponentový snímek v CMYK barevném prostoru $I_m$ .....	34
Obrázek 24: Postup detekce červených lézí s finálním vyobrazení detekovaných lézí na původním nativním snímku .....	35
Obrázek 25: (a) extrakce zelené chrominační složky, (b) extrakce zelené a červené chrominační vrstvy, (c) konečný obraz se zvýšeným kontrastem a sjednocením jasové intenzity .....	36
Obrázek 26: Výsledný snímek <i>connected component analysis</i> .....	37
Obrázek 27: Extrahované kandidátní retinální léze po klasifikaci SVM .....	37
Obrázek 28: (a) a (c) jsou nativní snímky v monochromatickém provedení, (b) a (d) prezentují výsledek detekce retinálních lézí .....	38
Obrázek 29: Příklady retinálních snímků, snímek a) vyobrazuje normální sítnici, snímek b) vyobrazuje sítnici s patologiemi v podobě Mikroaneurysmat a hemoragií .....	39
Obrázek 30: Blokové schéma průběhu algoritmu metody .....	39
Obrázek 31: Snímek po předzpracování .....	40

Obrázek 32: Snímek po transformaci roztažením minim .....	40
Obrázek 33: Extrahované cévy sítnice .....	41
Obrázek 34: Detekované světlé léze neboli exsudáty .....	41
Obrázek 35: Detekované MA .....	42
Obrázek 36: Příklady výsledků detekce s porovnáním od nativního snímku, přes předzpracování, až po zobrazení detekovaných lézí na předzpracovaném snímku .....	42
Obrázek 37: Demonstrativní snímek s detekovanými lézemi (modré oblasti) a exsudáty (zelené oblasti) .....	43
Obrázek 38: Příklady retinálních snímků .....	44
Obrázek 39: Snímek sítnice .....	44
Obrázek 40: Snímky zahrnující zastoupení retinálních lézí .....	45
Obrázek 41: Blokové schéma návrhu algoritmu pro analýzu retinálních lézí .....	46
Obrázek 42: Blokové schéma jednotlivých procesů předzpracování obrazu .....	47
Obrázek 43: Barevný RGB nativní snímek .....	48
Obrázek 44: Jednotlivé chrominační vrstvy RGB snímku .....	48
Obrázek 45: Snímek s extrahovanou zelenou a červenou chrominační vrstvou .....	48
Obrázek 46: Snímek s extrahovanými chrominačními složkami (vlevo), monochromatický snímek (vpravo) .....	49
Obrázek 47: Ukázka kódu pro extrakci zelené a červené chrominační složky obrazu .....	49
Obrázek 48: Ekvalizace histogramu .....	49
Obrázek 49: Ukázka ekvalizace histogramu .....	50
Obrázek 50: Rozdělení jasových transformací .....	50
Obrázek 51: (Vlevo) je snímek před jasovou transformací, (vpravo) po provedení operace jasové transformace .....	51
Obrázek 52: Snímek před mediánovou filtrací (vlevo) a po provedení filtrace (vpravo) .....	51
Obrázek 53: Ukázka mediánové filtrace na jedné retinální lézi .....	51
Obrázek 54: Blokové schéma procesů segmentace obrazu .....	52
Obrázek 55: Energetická mapa snímku .....	52
Obrázek 56: Deformace křivky aktivní kontury v rámci 300 iterací .....	55
Obrázek 57: Tři detekované léze na retinálním snímku .....	55
Obrázek 58: Proces binarizace jedné léze, zleva: nativní monochromatická data, segmentace léze na bázi aktivních kontur (xy iterací), energetická mapa aktivních kontur a výsledný binární model na základě prahování energetické mapy .....	56
Obrázek 59: Ukázka kódu pro binarizaci obrazu .....	56
Obrázek 60: Snímek s detekovanými konturami (vlevo), binarizovaný snímek (vpravo) .....	56
Obrázek 61: Proces vytvoření binárního segmentačního modelu více retinálních lézí .....	57
Obrázek 62: Nativní snímek (vlevo), ohraničené léze aktivními konturami (vpravo) .....	58
Obrázek 63: Klasifikace lézí pomocí image labeling .....	58
Obrázek 64: Ukázka kódu v MATLABu pro zjištění plochy a poloměru retinální léze .....	59
Obrázek 65: Proces metody registrace obrazu .....	60
Obrázek 66: Vliv předzpracování obrazu na viditelnost léze. Vlevo nativní snímky, vpravo snímky po předzpracování obrazu .....	62
Obrázek 67: Výsledné detekované léze (vlevo) nativní snímek, (vpravo) snímek po preprocessingu .....	63

Obrázek 68: Druhý příklad důležitosti předzpracování obrazu. Detekované léze na nativních datech (vlevo), předzpracovaný snímek (vpravo) .....	63
Obrázek 69: Vliv počtu iterací na modelování kontry. (a) předdimenzováno – 300 iterací, (b) poddimenzováno – 50 iterací, (c) optimální nastavení – 150 iterací.....	64
Obrázek 70: Výsledné detekované léze v závislosti na zvolení poloměru inicializační kontury při počtu 150 iterací. (a) předdimenzováno $r = 10$ , (b) poddimenzováno $r = 2$ , (c) optimální nastavení $r = 5$ .....	65
Obrázek 71: Výsledné detekované léze v závislosti na zvolení délky časového kroku při počtu 150 iterací. (a) předdimenzováno – timestep = 0.5, (b) poddimenzováno – timestep = 0.001, (c) optimální nastavení – timestep = 0.01 .....	65
Obrázek 72: Rozdíl v kvalitě snímku v závislosti na velikosti obrazu. (A) nativní snímek – originální velikost, (B) redukovaný snímek – 50 % originální velikosti, (C) redukovaný snímek – 20 % originální velikosti .....	66
Obrázek 73: Segmentační model - (vlevo) originální snímek, (vpravo) redukovaný snímek..	67
Obrázek 74: Detail segmentované léze - (vlevo) originální velikost, (vpravo) redukovaný snímek .....	67
Obrázek 75: Výsledná aktivní kontura při použití stejného nastavení pro zmenšený a originální snímek. (Vlevo) ohraničená léze zmenšeného snímku, (vpravo) ohraničená léze originálního snímku	67
Obrázek 76: Výsledek modelace deformační křivky při použití nastavení pro originální velikost na zmenšeném obrazu .....	68
Obrázek 77: (vlevo) běžný snímek, (vpravo) výběr oblasti zájmu RoI.....	69
Obrázek 78: RoI vybrané retinální léze.....	69
Obrázek 79: Energetická mapa ROI jedné retinální léze .....	69
Obrázek 80: Finální segmentace retinální léze v RoI při počtu 300 iterací.....	70
Obrázek 81: Segmentační model RoI retinální léze .....	70
Obrázek 82: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami	71
Obrázek 83: (Vlevo) Binární segmentační model lézí, (vpravo) klasifikační model umožňující diferenciaci jednotlivých lézí. ....	72
Obrázek 84: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku.....	72
Obrázek 85: Očíslované retinální léze.....	73
Obrázek 86: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami	74
Obrázek 87: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu .....	74
Obrázek 88: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku.....	74
Obrázek 89: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami	75
Obrázek 90: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu .....	75
Obrázek 91: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku.....	75
Obrázek 92: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami	76
Obrázek 93: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu .....	76

Obrázek 94: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku .....	76
Obrázek 95: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami .....	77
Obrázek 96: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu .....	77
Obrázek 97: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku .....	77
Obrázek 98: Diferencované léze z testovacího snímku č. 1. ....	78
Obrázek 99: Diferencované léze testovacího snímku č. 2. ....	79
Obrázek 100: Diferencované léze testovacího snímku č. 3. ....	79
Obrázek 101: Diferencované léze testovacího snímku č. 4. ....	80
Obrázek 102: Diferencované léze testovacího snímku č. 5. ....	80



## SEZNAM TABULEK

Tabulka 1: Technické parametry přístroje RetCam3 [27] .....	20
Tabulka 2: Ostatní parametry integrovaného mobilního vozíku [27] .....	21
Tabulka 3: Tabulka různorodosti znaků .....	27
Tabulka 4: Tabulka časů modelace aktivní kontury pro různé počty iterací .....	64
Tabulka 5: Tabulka časů modelace deformační křivky pro různé velikosti obrazu .....	68
Tabulka 6: Tabulka časů modelace aktivních kontur pro jednotlivé léze, při 200 iteracích ....	73
Tabulka 7: Geometrické parametry retinálních lézí ze snímku č. 1. ....	78
Tabulka 8: Geometrické parametry retinálních lézí ze snímku č. 2. ....	79
Tabulka 9: Geometrické parametry retinálních lézí ze snímku č. 3. ....	79
Tabulka 10: Geometrické parametry retinálních lézí ze snímku č. 4. ....	80
Tabulka 11: Geometrické parametry retinálních lézí ze snímku č. 5. ....	80

# 1 ÚVOD

Onemocněním retinopatií nedonošených (ROP) mohou trpět předčasně narozené děti. Toto onemocnění je nejčastější příčinou slepoty vzniklé v dětském věku. Součástí screeningu a diagnostiky ROP je kvalitní zpracování obrazových záznamů sítnice dětí, trpících tímto onemocněním. Navržením a realizací funkčního automatického algoritmu pro analýzu a modelování retinálních lézí, diferenciaci a extrakci geometrických parametrů, dochází k usnadnění práce oftalmologů, zjednodušení a zkvalitnění diagnostiky onemocnění, jež jsou stěžejními faktory pro zabránění oslepnutí nedonošených novorozenců.

Cílem této diplomové práce je vytvoření funkčního algoritmu pro analýzu a modelování retinálních lézí, extrakci geometrických parametrů, diferenciaci a unifikaci pozice segmentovaných lézí. Obsahem práce není pouze prezentace navrženého algoritmu a principů použitých metod, ale také seznámení s onemocněním ROP. Tyto oblasti jsou nezbytné pro pochopení práce algoritmu a jeho zaměření.

Teoretická část diplomové práce je zaměřená na seznámení s onemocněním ROP. Součástí je také anatomický popis oka, který je nezbytný pro celkové pochopení projevů onemocnění retinopatií, což je popsáno v následujících kapitolách. Zde jsou rozebrány jednotlivá stádia a formy onemocnění, screening, diagnostika a metody intervence.

V rámci teoretické části je v diplomové práci zahrnuta také řešerše problematiky detekce retinálních lézí ze snímků sítnice. Zde jsou popsány již existující techniky a postupy modelace a analýzy sítnicových lézí. Z důvodu nulového počtu článků týkajících se přímo onemocnění ROP jsou zde zahrnuty články popisující segmentaci retinálních lézí vyskytujících se u diabetické retinopatie.

Praktická část zahrnuje popis návrhu a realizace algoritmu pro analýzu a modelaci retinálních lézí. Algoritmus zahrnuje dále také extrakci geometrických parametrů lézí, diferenciaci a unifikaci pozice lézí. V kapitolách praktické části jsou popsány jednotlivé principy metod zpracování obrazu zahrnutých v rámci navrženého algoritmu. Součástí je také testování navrženého algoritmu na reálných patientských datech.

Testování navrženého algoritmu je zaměřeno na řádné odzkoušení funkčnosti analyzačního algoritmu a srovnání s dalšími možnostmi realizace. Součástí testování je také prezentace dosažených výsledků.

## 2 ANATOMIE OKA

### 2.1 Stavba oka


Oko (lat. bullbus oculi) je jedním z nejdůležitějších smyslových orgánů lidského těla. Tento párový orgán, umístěný na obličejové části lebky, reaguje na světlo a obstarává člověku vnímání obrazové informace. Oční bulbus, chráněný očnicí, má tvar mírně asymetrické koule, o průměru zhruba 25 mm. Stěna oční koule je tvořena třemi koncentrickými vrstvami.

Zevní vrstva tunica fibrosa se diferencuje v rohovku a bělimu. Bělina (sclera) pokrývá povrch bulbu. Jedná se o tuhou kolagenní vazivovou blánu, ke které je upnuto okohybné svalstvo. Skléra postupně přechází v rohovku (corneu). Rohovka je průhledná vyklenutá část nacházející se v předním segmentu bulbu a dominuje optickou mohutností 40 dioptrií.

Střední vrstvu bulbu tvoří živnatka (uvea). Živnatka obsahuje četné cévní řečiště a také melanocyty – pigmentové buňky. Přední část živnatky je přeměněná v řasnaté tělísko (corpus ciliare) a duhovku (iris). Řasnaté tělísko s pomocí svalů umožňuje akomodaci čočky. Je tvořeno z hladkého svalstva a povrch je opatřen výběžky, na kterých je zavěšená čočka. Druhá část živnatky nazývaná duhovka, je kruhovitý útvar, složen z hladkého svalstva. Umožňuje rozšiřování a zužování zornice a tím reguluje množství pronikajícího světla na sítnici. Zornice je různě zbarvená, její zbarvení určuje množství pigmentových buněk. Za zornicí se nachází průhledná bikonvexní část čočka (lens). Čočka společně s rohovkou láme paprsky a tím zajišťují co nejpřesnější dopad na sítnici. Optická mohutnost čočky je okolo 15 dioptrií.

Poslední vrstvou bulbu je tunica nervosa ve které se rozprostírá sítnice(retina).

Další důležitou částí oka je výplň bulbu. Zde jsou zastoupeny dvě rozdílné tekutiny. První tekutinou je tzv. komorová voda. Tato hustá viskózní tekutina je tvořena z 99 % vodou a nachází se mezi čočkou a rohovkou. Komorová voda má za funkci výživu okolní tkáně, a především udržování nitroočního tlaku. Prostor za čočkou je vyplněn sklivcem. Toto průhledné rosolovité těleso tvoří z 98 % voda, zbylé prvky zastupuje chlorid sodný, bílkoviny a také kyselina hyaluronová, která má za následek rosolovitost sklivce. [1] [2]



Obrázek 1: Stavba oka [15]

## 2.2 Stavba sítnice

Sítnice je rozprostřena na nejvnitřnější části očního bulbu. Skládá se z několika vrstev a její tloušťka se pohybuje okolo 0,2 – 0,4 mm. Sítnice zpracovává světelný signál paprsku, který na ní dopadá po průchodu skrze čočku. Nejdůležitějšími částmi sítnice jsou světločivé buňky – tyčinky a čípky.


Tyčinky dominují na sítnici v počtu okolo 120 milionů. Jedná se o modifikované neurony, které přítomností rodopsinu, jenž se rozkládá po dopadu fotonu, zapříčiňují vznik elektrického impulsu. Tyčinky nerozlišují barvy, pouze odstíny šedi. Jsou citlivější na světelnou intenzitu, čímž umožňují vidění za šera.

Barvu vnímající buňky sítnice se nazývají tyčinky. Jejich počet dosahuje 6–7 milionů buněk. Intenzitu světla vnímají oproti tyčinkám méně citlivěji, čímž způsobují ztrátu barevného vidění za zhoršených světelných podmínek. Z funkčního hlediska existují tři typy čípků, rozlišené podle citlivosti na určitou barvu. Jsou to červené, modré a zelené. V čípkách je obsažen oční pigment jodopsin, který jsou specializován pro vnímání jednotlivých barev.

Další důležitou částí sítnice je žlutá skvrna (macula lutea). Tato část o průměru okolo 5 mm umístěná v zorné ose oka je místem nejostřejšího vidění. Zde je shromážděno největší množství čípků, kdežto tyčinky se zde nevyskytují vůbec.

Oblast postrádající zrakové buňky se nazývá slepá skvrna. Nachází se v blízkosti výstupu zrakového nervu ven ze sítnice. Zde dopadající paprsky nemohou být vnímány z důvodu absence tyčinek a čípků.

Oblast sbíhající se nervových vláken sítnice do očního nervu je pojmenována jako optický disk. Zde také vybíhají jemné žíly a tepénky sítnice. [1] [2]




Obrázek 2: Stavba sítnice [14]


### 2.2.1 Cévní zásobení sítnice

Hlavní zásobení sítnice je zajištěno arterií ophthalmica. Ta do očníce vstupuje skrze canalis opticus a následně se dělí. Další tepenné zásobení zprostředkovává a. centralis retinae, která vstupuje do nervus opticus a společně postupují až k papilla nervi optici, kde následuje dělení na horní a dolní větev a následné nasální a temporální dělení. Temporální větev zásobuje krví žlutou skvrnu. A. centralis zásobuje veškeré vrstvy sítnice, pouze tyčinky a čípky zásobují kapiláry cévnatky.

Žilní krev je ze sítnice odváděna horní a dolní vénou ophthalmica. [1] [2]



Obrázek 3: Cévy sítnice [16]



Obrázek 4: Cévní zásobení oka [17]



### 3 RETINOPATIE NEDONOŠENÝCH

Retinopatie nedonošených je vazoproliferativní onemocnění dětské sítnice, postihující především předčasně narozené děti s nízkou porodní váhou. Majoritními rizikovými faktory vzniku ROP je stupeň nezralosti a nízká porodní váha novorozence. Dalším významným činitelem je nadměrná koncentrace kyslíku v krvi způsobená podporou respirační nedostatečnosti nezralého novorozence. Společně s těmito faktory se na vzniku ROP podílí mnoho dalších faktorů. [3]


#### 3.1 Klasifikace retinopatie

Klasifikace retinopatie je založena na hodnocení několika charakteristických projevů vývoje a lokalizaci změn na sítnici. Jsou to lokalizace změn na sítnici podle zón, rozsah postižení sítnice podle sektorů odpovídajících hodinám ciferníku, závažnosti onemocnění podle strukturálních změn sítnice na hranici vaskularizované a avaskularizované části, a také přítomnost nebo absence abnormálně rozšířených a vinutých cév na zadním pólu oka. [6]

##### 3.1.1 Lokalizace změn na sítnici

Prvním bodem klasifikace je lokalizace změn na sítnici podle zón. Tento bod má zásadní význam v hodnocení prognózy onemocnění a následné načasování terapie u jednotlivých forem ROP. Zde můžeme říct, že čím víc se blíží změny k zadnímu pólu oka, tím horší je prognóza a vyšší naléhavost zahájení včasné léčby. Aby bylo možné změny lokalizovat, byla sítnice rozdělena na 3 kruhové zóny o různé velikosti, s centrem ve zřetelném terči. Označují se římskými číslicemi I-III.

Zóna I. je kruhová oblast o nejmenším poloměru, která odpovídá dvojnásobku vzdálenosti středu zřetelného terče ke středu makuly. Zóna II. směřuje k periferiím sítnice a zónu III. prezentuje malá srpkovitá oblast v nejvzdálenějších periferiích sítnice. [3] [6] [4]




Obrázek 5: Schéma hodnocení lokalizace a rozsahu změn na sítnici [18]

### 3.1.2 Hodnocení závažnosti onemocnění

Retinopatie nedonošených probíhá v pěti vývojových stádiích. Tato stadia jsou charakterizována změnami, které probíhají na hranici vaskularizované části sítnice a bezcévní části.

- Stádium 1 – První stádium je charakteristické bělavou demarkační linií, která odděluje vaskularizovanou část sítnice od bezcévní.
- Stádium 2 – Ve druhém stádiu dochází k rozšiřování linie a nabývání hřebenovitého tvaru. V tomto stádiu se mohou také objevit drobné neovaskularizace.
- Stádium 3 – Zde se vytváří extraretinální fibrovaskulární proliferace, která vyrůstá z hřebene demarkační linie a prorůstá do sklivce.
- Stádium 4 – Projevem čtvrtého stadia je částečné odchlípení sítnice a to buď bez postižení makuly nebo s postižením makuly.
- Stádium 5 – V tomto stádiu dochází ke kompletnímu odchlípení sítnice. [5] [4]



Obrázek 6: Stadia retinopatie nedonošených [19]

## 3.2 Screening a diagnostika

Screening ROP je prováděn u předčasně narozených dětí, a to formou pravidelných kontrol oftalmologem. Hlavním důvodem je včasné odhalení prvních projevů onemocnění, následné sledování dítěte a v případě zhoršení změn na sítnici včasné zahájení terapie. Do této skupiny se běžně zařazují děti narozené před 32. gestačním týdnem těhotenství a porodní váhou nižší než 1500 g. Screening dětí bývá zahájen vyšetřením v 5. postnatálním týdnu a 31. postkoncepčním týdnem věku dítěte. Vyšetření probíhá v pravidelných dvoutýdenních intervalech, které je možné přizpůsobit aktuálnímu vývoji nálezu sítnice. Screening obvykle probíhá do 40. postkoncepčního týdne věku dítěte, tedy do doby původního plánovaného narození dítěte. Zde je již sítnice zcela vyvinutá a vaskularizovaná. Dřívější screeningový program byl prováděn především vyšetřením nepřímým oftalmoskopem, dnes se z velké míry využívá retinální kamery. [1] [3] [4] [6]

### 3.2.1 RetCam 3

Jednou z možností provádění kontroly sítnice dětí a záznamu jejího vývoje je širokoúhlý zobrazovací systém RetCam3. Jedná se o retinální kameru firmy Clarity Medical Systém, která umožňuje pořízení kvalitního širokoúhlého záběru sítnice, pořízení videozáznamu a uchovávání dat v digitální podobě. Kamera zobrazuje sítnici v reálné nepřevrácené podobě, čímž eliminuje potencionální riziko chyby vyšetřujícího, oproti použití druhé vyšetřovací metody – nepřímého oftalmoskopu.

Mezi nesporné výhody retinální kamery patří vyměnitelné čočky. Ty umožňují pořízení záznamu sítnice o různém záběru, čímž vyobrazí i nevzdálenější místa na sítnici. Nejběžněji je pro screening dětské sítnice používána čočka o záběru 120°. Čočky s nižším úhlem záběru dominují lepšími kontrastními vlastnostmi a možností většího přiblížení detailů sítnice. Dalším nezanedbatelným přínosem retinální kamery je možnost snímat sítnice již dvoutýdenních novorozenců. [26]



Obrázek 7: Přístroj RetCam3 [20]

Tabulka 1: Technické parametry přístroje RetCam3 [27]

Parametry počítače	
Operační systém	Windows 7
Procesor	Pentium Dual Core 2,4 GHz
Připojení	LAN/Multi USB
HDD	1 TB
Systémová paměť	4 GB

**Tabulka 2: Ostatní parametry integrovaného mobilního vozíku [27]**

<b>Další parametry přístroje RetCam3</b>	
Monitor	21" x 23"
Pracovní deska	41"
Pracovní plocha	230 čtverný inch
Zobrazení monitoru	23"
Napájení	Napájecí kabel, baterie
Tiskárna	Kombinovaná klasická s fototiskárnou
Baterie	Záložní baterie, provoz 15 min.
Ostatní	4 uzamykatelné zásuvky, fluorescenční modul pro angiografii

### **3.2.2 Nepřímá oftalmoskopie**

Duhou možností provádění screeningu dětí je nepřímá oftalmoskopie. U této vyšetřovací metody je využíváno upraveného zdroje světla a spojné čočky, s optickou mohutností 20-30 dioptrií. Nepřímý oftalmoskop je umístěn na hlavě vyšetřujícího lékaře, zde je také situován zdroj světla, čočka se klade do blízkosti vyšetřovaného oka. Obraz očního pozadí, který lékař vidí je obrácen, a pozorovatelná oblast dosahuje pouze 45°. [3]



**Obrázek 8: Nepřímý oftalmoskop [21]**

## **3.3 Léčba ROP**

Ve většině případů onemocnění retinopatií nedonošených dochází ke spontánnímu vyléčení bez jakéhokoliv zásahu a bez funkčního deficitu. Pouze u malé části vyšetřovaných dětí dochází k dalšímu rozšíření onemocnění a nutnosti léčebné intervence. Pro terapii je využíváno několika metod. Tyto metody jsou zaměřeny na destrukci periferních bezcévných částí sítnice a zabránění dalšímu šíření onemocnění do nejdůležitějších centrálních částí oka. [3] [6]

### **3.3.1 Kryoterapie sítnice**

Kryoterapie sítnice patří mezi nejstarší užívané metody terapie ROP. Principem je kryoterapie bezcévních periférií sítnice. Ablace je prováděná speciálně upravenou dětskou kryosondou, dosahující teploty  $-80\text{ }^{\circ}\text{C}$ , která se přikládá na povrch oka (spojivku).

Od této metody se v dnešní době ustupuje. Jednak zejména nutnosti použití anestezie, která je nebezpečná pro nedonošené novorozence, ale také z důvodu častých pooperačních komplikací provázejících tento zákrok. Výhodou této metody je kratší doba zásahu a tím menší zátěž na organismus novorozence a také možnost využití zákroku při snížené průchodnosti optických médií oka. [1] [3] [6]


### **3.3.2 Laserová fotokoagulace sítnice**

Šetrnější metodou léčebné terapie sítnice je laserová fotokoagulace. Nejčastěji je využíván diodový laser, který ničí tkáň teplem. Lasery umožňují přesnější zasazení jednotlivých fotokoagulačních bodů na sítnici a tím je tato metoda oproti kryoterapii účinnější a bezpečnější. Tato terapie je vhodnější zejména pro nezralé novorozence. Velkou nevýhodou diodového laseru je délka zákroku. Ta se pohybuje okolo 90 minut a z tohoto pohledu představuje větší zátěž na organismus dítěte. Dalším rizikem je také možnost popálení rohovky nebo čočky s následným vývojem šedého zákalu, a také omezení použití techniky při menší prostupnosti optických médií oka. [1] [3] [6]




## 4 RETINÁLNÍ LÉZE

V rámci onemocnění retinopatii nedonošených se mohou vyskytnout na sítnici retinální léze. Jedná se o krvácivé skvrny. Retinální léze ve většině případů nabývají menší cirkulární struktury, není to však pravidlem. Může se vyskytnout také rozsáhlejší krvácení. Na sítnici se objevují samostatně v určitém bodě sítnice nebo ve větším množství po celé ploše sítnice.




Obrázek 9: Příklad řidšího výskytu retinálních lézí



Obrázek 10: Hustší výskyt retinálních lézí

Je důležitou součástí screeningu onemocnění sledování vývoje retinálních lézí, především zda se krvácení nerozrůstá směrem k makule, která je místem nejostřejšího vidění



Obrázek 11: Místo nejostřejšího vidění – Makula [16]

## 5 REŠERŠE PROBLEMATIKY DETEKCE SÍTNICOVÝCH LÉZÍ

### 5.1 Detekce krvácivých lézí na snímcích očního pozadí pomocí Frangiho filtrů

V rámci předzpracování obrazu dochází k rozdělení snímku pomocí mřížky velikosti  $N \times M$  na dílčí obrazy, které jsou využívány pro snadnější detekování menších lézí. Každý dílčí snímek je následně vyhlazen Gaussovským filtrem a upraven kontrast pomocí adaptivního histogramu. Veškeré tyto operace jsou prováděny Matlabem, za předpokladu, že je ze snímku použita pouze zelená chrominační vrstva RGB obrazu a to z důvodu nejlepších kontrastních vlastností lézí na této chrominační vrstvě. Tímto předzpracováním obrazu dojde k celkovému snížení šumu snímku a zviditelnění lézí.


V druhé části dochází k navržení filtru pro extrakci kandidátních oblastí snímku, na kterých se vyskytují léze. Vytvoření potřebného filtru, Hessianova filtru dílčího obrazu, probíhá výpočtem aproximací první derivace jako konvoluce snímku derivovaného Gausovou metodou v měřítku  $s$ . Vlastní hodnota Haussova filtru vede k výpočtu tzv. lézivosti, tedy pravděpodobnosti výskytu léze v dané oblasti. V oblasti léze bude lézivost podstatně vyšší, oproti oblastem nedisponujícím sítnicovými lézemi. Pokud jsou  $\lambda_{1s}$  a  $\lambda_{2s}$  vlastní hodnoty Hessianu ( $|\lambda_{1s}| \leq |\lambda_{2s}|$ ) v měřítku  $s$  na základě pozorovaných vzorů  $\lambda_{1s}$  a  $\lambda_{2s}$ . Hodnota lézivosti je v měřítku  $s$  (*for*  $\lambda_{2s} \leq 0$ ) je dána:

$$L_s = \exp\left(-\left|1 - \frac{R_{Bs}}{2\beta^2}\right|\right) \left(1 - \exp\left(\frac{\Lambda_s^2}{2c^2}\right)\right) \quad (1)$$

$L_s$  je nastaven na hodnotu 0 pro  $\lambda_{2s} > 0$  pro potlačení tmavých struktur. Vzhledem k tomu, že červené léze jsou tmavé struktury je výstupní obraz invertován. V rovnici (1) je  $R_{Bs} = \lambda_{1s}/\lambda_{2s}$  a  $\Lambda_s = \sqrt{\lambda_{1s}^2 + \lambda_{2s}^2}$  při hodnotě  $\beta = 0,707$  a  $c (= 15)$  jsou konstanty, které řídí citlivost filtru. Parametr  $\Lambda_s$  rozlišuje zašuměné struktury, které jsou prezentovány trubcovými a podobnými útvary. Hodnota parametru  $R_{Bs}$  se blíží hodnotě 1 pro objekty podobajícím se lézím, protože pro tyto struktury jsou obě vlastní hodnoty očekávány na vyšší hodnotě. Zde se navrhané filtry liší od původního Frangiho filtru, který je primárně navržen pro detekci cév. U cév je hodnota  $R_{Bs} (= \frac{\lambda_{1s}}{\lambda_{2s}})$  nižší, protože pouze hodnota parametru  $\lambda_{2s}$  dosahuje vyšších hodnot, protože výpočet u cév je definován jako:

$$V_s = \exp\left(-\frac{R_{Bs}}{2\beta^2}\right) \left(1 - \exp\left(\frac{\Lambda_s^2}{2c^2}\right)\right) \quad (2)$$

Navržená modifikace pomáhá rozlišit lézi od cévy, což původní Frangiho filtry nebyly schopny odlišit. Za povšimnutí stojí, že hodnota  $L_s$  je v měřítku  $s$ . Finální odhad lézivosti pro určitou lézi je definováno jako maximum lézivosti nad všemi použitými hodnotami  $s$  s užitím různého  $s$  pro detekci lézí rozdílných velikostí. Rozmanitost hodnot  $s$  byla od 1 do 8 s krokem 0,2 pro MA (mikroaneurisma), a hodnoty 9 až 16 s krokem 0,2 pro H (hemoragie). Vzhledem k tomu, že se na snímku mohou nacházet dvě léze, které je nutné detekovat jsou použity dva filtry s jedinou odpovědí. Na zkušebním snímku byly použity oba filtry, a odpovědi každého z nich byl zaznamenáván typ léze, pokud léze existuje. Odezvy filtrů můžeme vidět na obrázcích.



**Obrázek 12: Výstupy po aplikaci filtru na jednotlivé léze. (a) je pro MA, (b) je pro H**

Mapa odpovědí obsahuje jednu hodnotu pro každý pixel ve výstupním dílčím snímku. Necht' je  $r_{max}$  maximální hodnotou v mapě odpovědí pro  $i^{th}$  dílčího snímku odpovídající filtru určeného pro detekci lézí  $o$ . Dále je využíváno maxima z mapy odpovědí jako odpovídající vlastnost. Pokud je H a MA odkaz na lézi, bude  $R_i = [r_{i,H}^{max} \ r_{i,MA}^{max}]$ . Pokud  $N_{sub}(= N^2)$  je celkový počet dílčích snímků, je vektor vlastností vytvořen jako  $F_I = [R_1 \ R_2 \ R_3 \ ... \ R_{N_{sub}}]$ . Vlastnosti extrahované z tréninkového data setu snímků byly využity k vytvoření podpůrného vektoru (SMV) klasifikovaného RBF jádrem. Pro každou lézi byl jeden klasifikátor vycvičen pro predikci nebo absenci léze na testovaném snímku. [13]

## 5.2 Automatická detekce krvácivých lézí v přítomnosti krevních cév morfologickými operacemi

V rámci předzpracování obrazu dochází k úpravám nedostatků na snímcích, které mohou vznikat v důsledku špatných technických vlastností záznamového zařízení nebo selháním lidského faktoru. V této metodě je prováděno potlačení šumu retinálních snímků, zvýšení kontrastu pro lepší viditelnost lézí a také normalizace barev na snímku. Dále je také provedena standardizace velikosti snímku. Následné úpravy jsou prováděny pouze na pixely v popředí, pixely v pozadí jsou potlačeny. Dále je vytvořena maska nalezením středu obrazu. Pro následné zpracování je využíváno zeleného kanálu snímku, který vyobrazuje krevní cévy a krvácení s nejlepšími kontrastními vlastnostmi. Pro optimalizaci kontrastu je využito CLAHE metody, která dostatečně zviditelňuje požadované objekty retinálního obrazu.



Obrázek 13: Vstupní nativní snímek

Druhým krokem je eliminace Fovey a celého optického terče, která bývá centrována ve středu snímku.

Během předzpracování je také detekováno krevní řečiště sítnice. Pro odstranění malých tmavých oblastí je využíváno operace morfologického uzavírání. Dva strukturální prvky S1 a S2 o různých velikostech za předpokladu, že S2 je větší než S1, slouží pro detekování silných krevních cév řečiště. Operace morfologickým uzavíráním se provádí pro S1 a S2. Výsledky morfologického uzavření snímků jsou od sebe odečteny a porovnány s prahovou hodnotou. Operace morfologického otevírání je použita pouze pro zjemnění snímku. Konečným výstupem je morfologicky dilatovaný snímek se strukturálními elementy.


V dalším kroku jsou detekovány kandidátní léze. To má za výsledek detekování podezřelých objektů vypadajících jako krvácení, označovaných jako kandidáti. Tito kandidáti jsou dále zkoumání, zda se jedná opravdu o lézi nebo pouze o nesprávně detekovaný objekt. Navrhovaná metoda se zaměřuje na nalezení velmi tmavých pixelů obsažených na zeleném kanále snímků. Toto je prováděno pomocí Otsu metody, která je aplikována na předzpracovaný snímek. Následně je opět použito morfologické uzavírání na výsledný snímek. Dále je provedeno vyhlazení snímku mediánovou filtrací, kdy je zvolené jádro velikosti 3x3 pixely. V tomto kroku je také extrahováno krevní řečiště, a to odečtením detekovaného řečiště od vyhlazeného snímku.

Pro každého kandidáta vybraného předchozími procesy, jsou vybírány společné znaky. Níže uvedená tabulka uvádí různé typy znaků, které jsou extrahovány pro každého kandidáta.

**Tabulka 3: Tabulka různorodosti znaků**

Znak	Popis
Textura	Statistiky výskytové matice zeleného kanálu snímku, lokální rozsah, směrodatná odchylka, entropie kandidátních pixelů
Barva	Průměrná směrodatná odchylka kandidátních pixelů v různých barevných prostorech
Histogram	Vypočítaná funkce založena na histogramu snímku, jako je průměr, rozptyl, šikmost, energie atd.
Wavelet	Střední hodnota, entropie, směrodatná odchylka

Další část publikace je věnovaná detekci tmavých retinálních lézí na snímku. SVM vektory jsou využívány pro binární klasifikace. SVM dosahuje nejlepších výsledků, pokud mají data přesně dvě třídy. SVM klasifikace je uskutečněna hledáním nejlepší hyper roviny, která rozdělí data jedné třídy na další třídu efektivněji. Klasifikátory SVM mohou být použity jak pro klasifikaci, tak pro regresní úlohy. SVM vektory fungují velice efektivně i na větších dimenzionálních prostorech. Nicméně, pokud je počet znaků větší, než počet vzorků výkon SVM klesá. Pro příklad máme data obsahující červenou a zelenou složku. Dělení roviny nastavuje hraniční nebo rozhodovací čára, která ukazuje, že objekty na pravé straně roviny patří do zelené třídy a objekty nacházející se na levé části roviny spadají do třídy červené. Na tomto příkladu je vysvětlená lineární klasifikace, která identifikuje objekty do odpovídajících tříd. [12]

**Obrázek 14: SVM klasifikace**





**Obrázek 15: Blokové schéma průběhu zpracování obrazu popisované metody**




**Obrázek 16: Výsledek celého procesu – detekované krvácivé léze**

### 5.3 Detekce abnormalit na fundus snímcích sítnice

Před samotným zpracováním obrazu probíhá prostorová kalibrace. Ta slouží pro oddělení oblastí zájmu od pozadí. Používají se tři hodnoty pixelů  $p_1$ ,  $p_2$ ,  $p_3$  rozmístěných na hranicích snímku. Následně je nakreslená spojovací čára  $p_1$ ,  $p_2$  a  $p_1$ ,  $p_3$ . Dále jsou nalezeny středy těchto dvou čar, označeny jako  $p_4$ ,  $p_5$  a také tyto body jsou spojeny čarou. Střed této nové čáry je označen jako centrum obrázku. Ze středu je vypočítaná hodnota středového průměru  $D$  a ta dále slouží pro výpočet hodnoty jádra tří parametrů:

- $d_1$  je průměrný poloměr optického disku (OD)
- $d_2$  je průměrný poloměr mikroaneurysmat (MA)
- $d_3$  je průměrný poloměr hemoragií (H)



Obrázek 17: Prostorová kalibrace

Předpracování snímku je směřováno k potlačení nestejnorodosti osvětlení sítnice. Vzhledem k tomu, že se léze mohou nacházet i v hůře osvětlených oblastech, je nutné určitými úpravami sjednotit osvětlení snímku. Dále je provedeno zvýšení kontrastu snímku.

K vyrovnaní osvětlení je použit velký průměrový filtr ( $hM1$ ) o průměru ( $d1$ ). Ten je aplikován na každou barevnou komponentu originálního snímku za účelem odhadu jeho osvětlení. Poté je výsledný barevný snímek odečtený od originálního snímku pro opravu potenciálů nesrovnalosti osvětlení. Nakonec je přidána průměrná intenzita originálního kanálu pro zachování stejného rozsahu barev jako na originálním snímku. To je určeno rovnicí  $I_{ie} = I + \mu - hM1$ , kde  $I_{ie}$  je ekvalizovaný snímek,  $I$  je barevný kanál snímku,  $\mu$  je průměrná intenzita a  $hM1$  je střední filtr o průměru  $d1$ .

Změna kontrastních vlastností snímku slouží pro zvýraznění detailů požadovaných objektů pro každou chrominační vrstvu odděleně. Lokální směrodatná odchylka  $Istd$  je vypočtená pro každou chrominační složku o průměru  $d3$ . Pak je střední filtr  $hM3$  vypočítán pro každou chrominační složku zvlášť, která je pak odečtená od hodnoty 1. Tato výsledná hodnota je následně vynásobena inverzí lokální směrodatné odchylky. To je popsáno rovnicí  $I_{ce} = \frac{1}{Istd} * (1 - hM3)$  kde  $I_{ce}$  je kontrastní ekvalizovaný snímek,  $Istd$  je lokální směrodatná odchylka pro každou chrominační složku a  $hM3$  je střední filtr o průměru  $d3$ .

Dalším krokem předzpracování je normalizace barev snímku. To je provedeno technikou roztahováním histogramu snímku. Roztažení histogramu je jednoduchá metoda, která mění kontrast snímku, ale především mění rozsah rozložení hodnot intenzity.

Po dokončení operací předzpracování nastává fáze extrakce optického disku. Vzhledem k tomu, že optický disk je významným zdrojem falešně pozitivních výsledků v detekci krvácivých lézí, je nezbytnou součástí celé metody extrahovat optický disk z předzpracovaného snímku. Odstranění je prováděno metodou morfologického otevírání a uzavírání. Morfologické otevírání zajišťuje odstranění


určitých objektů z popředí, to znamená jasných pixelů z okrajových oblastí popředí. Morfologickým uzavíráním dochází ke zvýraznění hranic světlých oblastí v popředí na snímku. Tyto morfologické operace jsou na snímku prováděny čtyřikrát, opakovaně za sebou. Výsledkem je detekování nejjasnějších pixelů na snímku, které prezentují optický disk.

Následuje extrakce kandidátních lézí na snímku, ze kterého byl v předchozí části extrahován optický disk. Z tohoto snímku je využívána pouze zelená chrominační vrstva, která nejviditelněji zobrazuje kandidátní oblasti. Tmavé oblasti snímku jsou separovány a světlé pixely jsou nastaveny na nižší kontrastní hodnotu, čímž jsou potlačeny do pozadí.

Dále jsou zjišťovány dynamické a tvarové vlastnosti kandidátů (DSF). Jelikož mezi kandidáty mohou být klasifikovány i oblasti, které nejsou lézemi, například cévy sítnice, nebo jiné patologie. Proto je nutné dobře rozlišit mezi pravými lézemi a falešně pozitivními. K tomuto rozlišení slouží popis pomocí dynamických vlastností a znaků. Je použita metoda morfologického zaplňování, které začíná na nejnižším zdroji zaplnění a končí při dosažení retinálního pozadí ( $I_{stop}$ ). Při každé úrovni zaplnění  $i$  jsou pixely, které sousedí se zdrojem zaplnění  $s_j$  a nižší než úroveň zaplnění  $i$ , přidány do třídy a označeny. Jakmile jsou dvě třídy spojeny, začnou sdílet stejné pixely a tytéž atributy. Snímek je zaplněn pomocí hierarchické fronty. Na každé úrovni zaplnění je vypočítáno z třídy  $\beta_i^{s_j}$  pro každého kandidáta  $s_j$ , šest tvarových atribut. Jsou to:


- Relativní oblast ( $R_{area}$ ): Počet pixelů v  $\beta_i^{s_j}$  děleno celkovým počtem všech pixelů v oblasti zájmu.
- Prodloužení ( $E_{long}$ ):  $1 - \frac{W}{L}$  Kde  $W$  a  $L$  je šířka a délka hraničního boxu orientovaného podél hlavní osy
- Excentricita ( $E_{cc}$ ):  $\sqrt{L^2 \frac{W^2}{L^2}}$  Kde  $W$  a  $L$  je šířka a délka hraničního boxu orientovaného podél hlavní osy
- Kruhovitost ( $C_{irc}$ ): Poměr plochy  $\beta_i^{s_j}$  okolo hraničního boxu vynásobeno  $4\pi$
- Pravoúhlost ( $R_{ect}$ ): Poměr plochy  $\beta_i^{s_j}$  nad oblasti hraničního boxu orientovaného podél hlavní osy
- Pevnost ( $S_{ol}$ ): Poměr plochy  $\beta_i^{s_j}$  nad oblasti jeho konvexního obalu

Je získáno šest křivek pro každého kandidáta, jedna křivka na jeden tvarový atribut. Všechny tvarové atributy, a to  $R_{area}$ ,  $E_{long}$ ,  $E_{cc}$ ,  $C_{irc}$ ,  $R_{ect}$ ,  $S_{ol}$  jsou funkcemi hladiny zaplnění. Na každé křivce je provedena metoda lineárních nejmenších čtverců. Skupina  $K$  lineárního polynomickeho uložení je nastavena experimentálně. Záleží na pořadí uložení, počet regresivních parametrů se rovná  $+1$ . Tyto parametry a kořenový průměr přizpůsobení znamenají čtvercovou chybu uložení, tvoří první funkce  $K + 2$ . Poslední dvě funkce představují střední hodnota a hodnota úrovně zaplnění. Ve finální podobě to znamená  $6 * (k + 4)$  DSF jsou vypočteny pro každého kandidáta. V této metodě se používá atributů pevnosti a prodloužení, protože tyto vlastnosti nejlépe odpovídají krevním cévám, dále kruhovitosti, a to z důvodů většinou kruhového tvaru retinálních lézí.



**Obrázek 18: DSF zobrazeno na čtyřech kandidátech získaných ze snímku. S1 a S4 odpovídají krevním cévám, S2 a S3**


Posledním krokem metody je klasifikace. Po extrakci kandidátů je provedena jejich klasifikace, a to metodou SVM. Tento koncept funguje na principu rozhodovacích rovin definovaných rozhodovacími hranicemi. Rozhodovací rovina odděluje množinu prvků s různými třídami. SVM je primárně nejklasičtější metoda, která provádí klasifikační úkoly pomocí konstrukce hyper rovin v multidimenzionálním prostoru, který odděluje prvky různých tříd. SVM podporuje regresivní a klasifikační úkoly a může zpracovávat více kontinuálních a kategorických proměnných. [11]



**Obrázek 19: Blokové schéma metody**


## 5.4 Nový přístup v detekci krvácivých retinálních lézí pomocí funkce Superpixel multi-features clasification v barevných snímcích očního pozadí

Celý tento algoritmus je složen z pěti etap. Jedná se o předzpracování, extrakce kandidátních regionů, extrakce znaků, klasifikace a následné zpracování. V první fázi dochází k úpravě osvětlení snímku a kontrastu. V druhé části je provedena segmentace superpixelů k získání červených struktur. Následně jsou extrahovány kandidátské regiony. Po této fázi je použitý FDA klasifikátor pro trénink a klasifikaci kandidátních regionů. Poslední fázi je následné zpracování. To zahrnuje techniky pro odstranění krevních cév a fovey a získání konečných výsledků detekce.



Obrázek 20: Blokové schéma jednotlivých operací detekce


V rámci předzpracování dochází ke sjednocení osvětlení na snímku, a to z důvodu, že na retinálních snímcích je osvětlení téměř ve všech případech nestejnorodé. V tomto algoritmu je využíváno metody adaptivního vyrovnání histogramu, to znamená operace CLAHE. Díky této operaci dochází ke zviditelnění a zvýraznění objektů snímku.



Obrázek 21: Příklady použití metody CLAHE na dvou retinálních snímcích. Snímky (a) a (b) jsou nativní obrazy, (b) a (c) vyobrazují upravené snímky metodou CLAHE

Následuje výběr kandidátních regionů na základě metody SLIC. Metoda SLIC neboli jednoduché lineární iterační klastrování, se využívá k vytváření superpixelů. Dominuje nízkou

výpočetní náročností vzhledem k přesnosti segmentace hranic. Metoda je založena jak na barevné vlastnosti, tak na vzdálenosti k provádění segmentace superpixelu. Důležitým parametrem této metody je velikost regionu, která rozhoduje o tom kolik pixelů bude tvořit superpixel.



**Obrázek 22: Segmentace metodou SLIC. (a) předzpracovaný snímek, (b) detailní zobrazení léze, (c-e) superpixelová segmentace s velikostí oblastí 10, 30 a 50 pixelů**

Vzhledem k faktu, že je velice těžké rozlišit retinální léze od pozadí v tradičním barevném prostoru RGB, je využito metody extrakce různých rysů v několika kanálech snímků (série rozlišných kanálů snímků závislých na originálním snímku) pro reprezentaci každého segmentovaného superpixelu. Zde je  $I_{clahe}$  je proměnná předzpracovaného snímku CLAHE metodou,  $I_{original}$  proměnná nativního snímku a  $I_{green}$  je zelená chrominační složka  $I_{clahe}$  snímku. Vícekanálové snímky jsou popsány takto:


- Kanál 1–2: Originální snímek v monochromatické provedení a předzpracovaný monochromatický snímek metodou CLAHE
- Kanál 3: Snímek po střídavém sekvenčním filtrování ASF. Toto filtrování zahrnuje operace morfologického otevírání a zavírání s různou velikostí strukturálních elementů  $K$  použitého pro odhad pozadí předzpracovaných snímků v rovnici (3). Výsledný snímek předzpracování je odstraněn od výsledku ASF filtrování  $I_{ASF}$  a je získán snímek tmavý a zvětšený  $I_{dark\_enhanced}$ .

$$f_{ASF} = \vartheta^{nK} \left( \dots \left( \varphi^{2K} \left( \vartheta^K \left( \varphi^K (f_{CLAHE}) \right) \right) \right) \dots \right) \quad (3)$$

- Kanál 4: Operace morfologického uzavírání  $I_{close}$  je aplikována na  $I_{green}$  pro eliminaci malých a tenkých objektů pomocí diskového strukturálního elementu
- Kanál 5: Korekce jasu pro  $I_{green}$  zapříčiní sjednocení jasových hodnot.



- Kanál 6:  $I_m$  je  $M$  komponentů předzpracovaného původního retinálního snímku převedeného do CMYK barevného prostoru.



**Obrázek 23: (a) originální monochromatický snímek  $I_{green}$ , (b-f) vylepšené obrazy zelené chrominační složky, zvýrazněné struktury s nízkou intenzitou  $I_{dark\_enhanced}$ , operace morfologického uzavírání  $I_{close}$ , barevně sjednocený snímek  $I_{hue\_enhanced}$  a  $M$  komponentový snímek v CMYK barevném prostoru  $I_m$**

Se šesti kanály je navrženo 26 funkcí zahrnujících maximum, minimum, střední hodnotu a medián každého kandidáta v originálním monochromatickém obrazu, předzpracovaném monochromatickém snímku a vícekanálovém snímku. Navíc je odvozena také průměrná intenzita a směrodatná odchylka pro každý kanál. Kromě výše uvedených 26 funkcí, popisovaná metoda vyvinula nový a efektivní prvek který má za cíl lépe popsat kandidátní regiony užitím střední intenzity a vzdálenosti mezi centry kandidátních regionů. Tato metoda je popsána následovně:

$$S_i = \frac{\sum_{j \in N(i)} \left( \frac{av\_G_i}{av\_I_{green}} \times \frac{d_1}{d_2} \right)}{N_i} \quad (4)$$

$$d_1 = \|av\_G_i - av\_G_j\|_2^2 \text{ pokud } av\_G_i \leq av\_G_j \quad (5)$$

$$d_1 = \|av\_G_i - av\_G_j\|_2^2 \times (-1) \text{ pokud } av\_G_i > av\_G_j \quad (6)$$


$$d_2 = \|p_i - p_j\|_2^2 = \left\| \frac{\sum_{I_M \in R_i} I_m^p}{|R_i|} - \frac{\sum_{I_M \in R_j} I_m^p}{|R_j|} \right\|_2^2 \quad j \in N(i) \quad (7)$$

Kde  $d_1$  je střední hodnota rozdílu intenzity mezi sousedními kandidátními regiony a  $d_2$  je rozdíl mezi pozici center sousedních kandidátních regionů.  $I_m^p$  je vektor pozice centra sestavený z pozice vektoru pixelu  $I_m$ ,  $\|\cdot\|_2^2$  je kvadratická funkce druhé úrovně.  $N(i)$  jsou sousední kandidátní oblasti z  $i$  a  $N_i$  je konečný počet pixelů kandidátní oblasti  $i$ . Zde je soused definován jako sedminásobek velikosti regionu. V podstatě je potřeba vypočítat střední hodnotu  $av\_G_i$  pro každý superpixel, aby se eliminoval vliv šedé nestejnorodosti způsobené rozdílným osvětlením sítnice, nebo špatným úhlem kamery. Je nutné

zohlednit následující faktory. Nejprve uvedeme střední hodnotu  $av_{I_{green}}$  původního snímku do rovnice (2). Poté šedá vzdálenost  $d_1$  je uvažována, jestliže superpixel patří k tmavým strukturám, tím je větší šedá vzdálenost s okolními pixely v určitém rozsahu. Za třetí, v druhém bodu je užívána šedá vzdálenost pro rozlišování tmavých struktur a má také souvislost s prostorovou vzdáleností  $d_2$  mezi dvěma superpixely. Nakonec, vzhledem k tomu, že superpixel má menší vliv na rozlišení, je šedá vzdálenost brána jako vynásobení reciproční prostorové vzdálenosti.

Předposlední část zahrnuje klasifikaci kandidátních regionů. Po extrakci prvků máme 27 dimenzionální vektor  $F = \{f_1, f_2, \dots, f_{27}\}$  pro každý segmentovaný superpixel. Dvě třídy superpixelů zahrnují červené léze a falešné červené léze. Následně je zavedena FDA analýza, která minimalizuje rozptýlení mezi třídami a současně minimalizuje rozptyl uvnitř třídy.

Poslední části jsou další úpravy. Zde dochází k potlačení falešně detekovaných lézí. Jako falešně detekovaná léze může být fovea a cévy sítnice. Pomocí morfologických operací můžeme extrahovat krevní cévy a v případě potřeby také optický disk. V této části je také sestavena finální mapa lézí. [10]




**Obrázek 24: Postup detekce červených lézí s finálním vyobrazení detekovaných lézí na původním nativním snímku**



## 5.5 Detekce retinálních lézí za použití morfologické operace a kvalifikace pixelů

Během předzpracování obrazu je využito informací ohledně jasových intenzit z červené a zelené chrominační složky snímku. K této operaci je přistoupeno z důvodu rozdílných výhod jednotlivých chrominačních složek obrazu. Zelená chrominační složka vyobrazuje sítnicové léze s nejlepšími kontrastními vlastnostmi, kdežto dominantou červené chrominační vrstvy je větší intenzita světla a širší rozklad v šedé barevné škále, naopak však kontrast objektů sítnice je v tomto případě nižší. Celkový kontrast retinálního obrazu je upraven operací *contrast stretching*. Dále je také nutné sjednotit intenzitu osvětlení pozadí snímku užitím mediánové filtrace.



**Obrázek 25: (a) extrakce zelené chrominační složky, (b) extrakce zelené a červené chrominační vrstvy, (c) konečný obraz se zvýšeným kontrastem a sjednocením jasové intenzity**

Zobrazení profilu šedé úrovně průřezu retinální léze může být apřoximováno Gausovou křivkou. K detekování červených retinálních lézí je využito detekce pomocí *matched filter detection*. Vzhledem k tomu že červené léze disponují špatným lokálním kontrastem, je navržen *two-dimensional matched filter kernel*, které zviditelní retinální léze snímku.


Vyjádření pomocí rovnice je následovné:

$$f(x,y) = -\exp\left(-\frac{x^2}{2\sigma^2}\right) \text{ pro } |y| \leq L/2 \quad (8)$$

Kde proměnná  $L$  znamená délku segmentu, pro kterou má daná céva předpoklad fixní orientace. Sada dvanácti jader o velikost 16x15 pixelů, je aplikovaná přilnutím k fundus obrazu kdy v každém pixelu obrazu je zachováno maximum jejich citlivosti. Tímto procesem dojde k zviditelnění krevního řečiště sítnice a také červených lézí. Pro kvalitní extrahování retinálních lézí ze snímku upravených *matched filter response* (MFR), je nezbytné provést efektivní prahování. Algoritmus pro prahování je založen na relativní entropii, kdy jsou zohledněny prostorové úrovně šedé barvy. Toho algoritmu je především využito z důvodu, že snímky po MFR mají velmi malý rozdíl mezi popředím a pozadím. Zvláště pak bývá implementována lokální relativní entropiová prahovací technika, která neznehodnotí strukturní detaily snímku. Celá tato prahovací technika slouží k minimalizaci rozdílnosti

Dalším důležitým krokem k úspěšné detekci retinálních lézí je extrakce krevního řečiště. Extrakce je provedena morfologickou *top-hat* technikou. Tato technika morfologicky otevírá snímek s lineárními strukturálními prvky o různých orientacích. Zahrnuje dvanáct rotujících strukturálních elementů s radiálním rozlišením 15 °. Následující operací proběhne odečtení transformovaného snímku

od prahovaného obrazu k segmentaci kandidátních lézí. Vzhledem k tomu, že retinální léze se běžně nevyskytují na velkých cévách sítnice, je možné tyto sítnice ze snímku extrahovat. Pro získání potencionálních kandidátních regionů je provedena operace *connected component analysis*. Objekty, které jsou příliš rozlehlé na to, aby mohly být retinální lézí, jsou ze snímku extrahovány pryč. V této metodě byl experimentálně nalezen práh 300 pixelů, který zahrnuje 98 % všech retinálních lézí. Vaskulární objekty většinou tvoří plochu o rozloze více než 300 pixelů, proto jej touto operací můžeme odstranit.



**Obrázek 26: Výsledný snímek *connected component analysis***

Následná klasifikace retinálních lézí je provedena pomocí SVM, což je statická metoda založena na minimalizaci strukturálního rizika. To mapuje vstupní vektor  $y$  na více rozměrové rysy prostoru za výběru nelineárního mapovacího jádra. Následujícím vztahem je definována optimální oddělovací nadrovina:

$$f(x) = \text{sgn}\left[\sum_{i=1}^l y_i \alpha_i k(x_i, x) + b\right] \quad (9)$$

Kde parametr  $y_i$  je  $k$  je jádrová funkce,  $\alpha_i$  jsou Lagrovy násobiče a  $b$  je úhlopříčka. V této metodě bylo použito lineární jádro a sjednocený parametr  $c = 10$ .




**Obrázek 27: Extrahované kandidátní retinální léze po klasifikaci SVM**

Pro řešení problémů jako je „jeden versus zbytek“ a „jeden versus jeden“, je často využíváno binární SVM klasifikace. Hlavním cílem této metody je správné klasifikování červených retinálních lézí a falešných retinálních lézí. Pro kvalitní klasifikování bylo zavedeno 12 přídavných funkcí, které byly vypočteny z výskytové matice. Mezi tyto funkce patří následující body. [9]


- Kontrast
- Korelace
- Úhlový moment setrvačnosti

- Součet čtverců
- Inverzní rozdílový moment
- Součet průměrů
- Součet rozptylů
- Součet entropie
- Entropie
- Rozdíl rozptylů
- Rozdíl entropie
- Měření informace pro korelaci



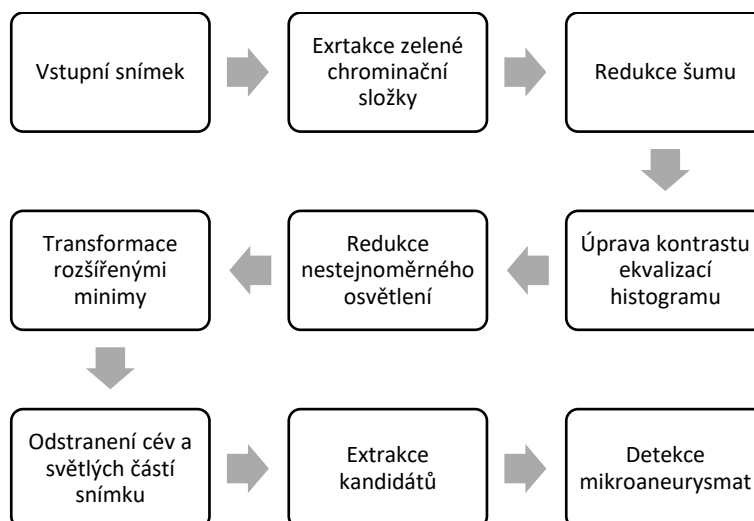
**Obrázek 28: (a) a (c) jsou nativní snímky v monochromatickém provedení, (b) a (d) prezentují výsledek detekce retinálních lézí**

## 5.6 Detekce mikroaneurysmat na retinálních snímcích morfologickým přístupem



Obrázek 29: Příklady retinálních snímků, snímek a) vyobrazuje normální sítnici, snímek b) vyobrazuje sítnici s patologiemi v podobě Mikroaneurysmat a hemoragií


Prezentovaná metoda popisuje detekci mikroaneurysmat (MA) z barevných fundus snímků sítnice. Metoda je založena na jednoduchých morfologických operacích a funkcích. Popisovaná metoda je jednoduchá a přesná.



Obrázek 30: Blokové schéma průběhu algoritmu metody

Během předzpracování je upravován 8 bitový RGB snímek sítnice. Celý proces předzpracování začíná výběrem zelené chrominační složky snímku, jelikož je kladeno za cíl detekování červených lézí, které jsou nejvíce kontrastní právě na zelené chrominační vrstvě barevného snímku. Na druhou stranu, červená a modrá chrominační vrstva potlačuje léze do pozadí, proto je možné obě tyto vrstvy potlačit. Dalším krokem předzpracování je odstranění zašumění snímku. MA se na snímku objevují jako malé tmavé tečky, které můžeme přirovnat k umělému šumu typu sůl a pepř. Díky této vlastnosti je obraz filtrován mediánovým filtrem o velikosti jádra 3x3. Po mediánové filtraci následuje vylepšení kontrastu pomocí adaptivní ekvalizace histogramu. Další také důležitou částí je sjednocení osvětlení snímku. Odchylky v osvětlení jsou odstraněny odečtením odhadu pozadí vstupního snímku od nativního vstupního snímku. Odhad pozadí je získán pomocí mediánové filtrace zelené chrominační složky

snímku, za užití většího jádra filtru. Následně je tento odhad odečten od původního snímku, čímž dojde k nejen k redukci variací osvětlení pozadí, ale také ke zlepšení zřetelnosti krevního řečiště sítnice a MA.



**Obrázek 31: Snímek po předzpracování**


Dalším postupem je transformace rozšířením minim. Transformace rozšířením minim je morfologickou operací zpracování. V podstatě se jedná o získávání regionálních minim z h-minimální transformace. Během h-minimální transformace jsou odfiltrovány všechny minima ze snímku na základě poskytnutého parametru kontrastu. Obraz vzniklý h-minimalizační transformací je získán pomocí rekonstrukce erozí  $R^\epsilon$  předzpracovaného snímku  $I$  podle  $I+h$ , pokud je hloubka  $h$  k dispozici.

$$h_{min} = R_I^\epsilon(I + h) \quad (10)$$

Regionální minima poskytují spojené komponenty snímku, takže všechny hraniční pixely mají nižší hodnotu, než je konstantní intenzita spojených komponent. V této metodě je rozšiřování minim aplikováno na předzpracovaný snímek  $I_p$ .

$$I_{extmin} = \{Ext\ min(I_p)\}_{|d=0,04} \quad (11)$$

Rovnice (11) udává transformaci prodloužením minima předzpracovaného obrazu. Hloubka je zvolena jako hodnota 0,04. Předzpracovaný snímek má změněné rozmezí úrovní šedých hodnot na hodnoty 0 až 1.



**Obrázek 32: Snímek po transformaci roztažením minim**


V následujícím bloku dochází k detekování vaskulatury sítnice a redukcí světlých oblastí. Jelikož retinální léze i cévy dominují na snímku stejným barevným spektrem, můžou být cévy při detekci falešně označeny jako léze. Extrakce cévního řečiště ze snímku je provedeno morfologickým uzavíráním. To je aplikováno na předzpracovaný snímek.

$$I_{closed} = (I_p \oplus SE_{disk}) \ominus SE_{disk} \quad (12)$$

Předzpracovaný snímek obsahuje MA jako tmavé tečky. Tyto tmavé tečky mohou být považovány za díry v předpracovaném snímku a tyto lze interpretovat jako odpojená regionální minima od okraje obrázku. Takto vyplněný obraz je získán odstraněním sady minim. Morfologicky získáme obrázek vyplněný otvory pomocí rekonstrukce erozí masky snímku, který je označen  $I_m$ . Snímek  $I_m$  je takový, který má maximální hodnotu pro každý pixel s výjimkou hranic. Je potřeba tyto otvory vyplnit pro extrakci cévního řečiště. Výsledný snímek je označen jako  $I_{fill}$ .

$$I_{fill} = R_{I_p}^E(I_M) \quad (13)$$

Z výše uvedené rovnice je  $I_m$  snímek, který má maximální hodnoty snímku, pro každý pixel  $p$  s výjimkou hranových pixelů. Snímek s detekovanými cévami je získán odečtením od vyplněného snímku  $I_{fill}$  od uzavřeného snímku.




**Obrázek 33: Extrahované cévy sítnice**

Jasně léze, známe jako exsudáty se objevují na sítnici ve skupinách blízko sebe. Odstranění cév je důležité, protože na jejich křížení může docházet k falešným detekcím lézí. Taktéž světlé léze mohou být zdrojem falešně pozitivních lézí. Proto obě tyto struktury jsou odstraněny ze snímku jako prevence




**Obrázek 34: Detekované světlé léze neboli exsudáty**

Posledním krokem metody je detekce kandidátů. To probíhá na základě určených kritérií oblasti. Předpokládá se, že MA disponují velikostí od 8 do 12 pixelů. [7]



**Obrázek 35: Detekované MA**



**Obrázek 36: Příklady výsledků detekce s porovnáním od nativního snímku, přes předzpracování, až po zobrazení detekovaných lézí na předzpracovaném snímku**



## 5.7 Automatická detekce diabetické retinopatie na digitálních retinálních snímcích: nástroj pro screening diabetické retinopatie

Zpracování obrazu v této metodě zahrnuje čtyři hlavní fáze. Patří sem předzpracování obrazu, identifikace normálních struktur, identifikace kandidátních lézí, extrakce kandidátních lézí. Celá klasifikace probíhá dvoufázově. Klasifikace pozitivních a falešně pozitivních lézí pomocí neuronových sítí, a ve druhé fázi je klasifikace snímku na úrovni s patologiemi a bez pomoci matematických pravidel.

Předzpracování zahrnuje vylepšení kontrastních vlastností snímku. To je prováděno z důvodu ztráty kontrastní informace směrem k okrajům obrázku. Kontrast je zvýšen pomocí lokálního zvýšení kontrastní hodnoty. Pro zjednodušení práce byla také standardizována barevná škála podle typického fundus snímku.


Dále probíhá identifikace na sítnici tzn. cév sítnice a optického disku. Optický disk můžeme popsat jako místo maximálního kontrastu na sítnici. Toho je dosaženo vytvořením rozptylu a určením vrcholu intenzity v rámci tohoto snímku. Detekce vaskulárního stromu sítnice je v této studii dosaženo Gausovsky tvarovaným multi-rozhodovacím filtrem o 16 orientacích.

Pro identifikaci kandidátních retinálních lézí je nutné extrahovat ze snímku také světlé exsudátní léze. To je provedeno pomocí segmentace rekurzivní rostoucí oblasti a adaptivní prahovou intenzitou. Tmavé léze jsou detekovány podobným způsobem, ale za použití speciálně vyvinutého operátoru zvýšení viditelnosti hran.

Pro každého detekovaného kandidáta je vyextrahována pro kvalifikaci velikost, tvar, odstín a intenzita barvy.

Klasifikace léze, zda je opravdu lézí, nebo se jedná o falešně detekovaného kandidáta léze, je prováděná pomocí neuronové sítě.

Posledním krokem je kvalifikace snímku, zda se jedná o normálního pacienta nebo abnormálního obsahující patologie. Klasifikace je řízena tím, zda se na daném snímku vyskytly retinální léze či naopak. [8]




**Obrázek 37: Demonstrativní snímek s detekovanými lézemi (modré oblasti) a exsudáty (zelené oblasti)**




## 6 ANALÝZA PACIENTSKÝCH DAT

Testování navrženého algoritmu pro analýzu sítnicových lézí vyskytujících se při retinopatii nedonošených probíhalo na reálných datech pacientů, trpících tímto onemocněním. Jedná se o anonymní obrazová data sítnice zaznamenané retinální kamerou RetCam3. Obrazová data pro testování algoritmu poskytlo Centrum pro děti s vadami zraku Oční kliniky Fakultní nemocnice Ostrava. Snímky disponují rozlišením 640x480 pixelů. Kvalita pořízeného snímku sítnice závisí na lékaři a jeho práci s retinální kamerou, ale také na dalších faktorech jako je například stav rozkapání zornice pacienta. To je hlavní původ široké rozdílnosti kvality retinálních snímku v dostupném souboru dat. Rozdíly jsou především v ostrosti objektů a jasových vlastnostech snímku.



Obrázek 38: Příklady retinálních snímků

Obvykle je na snímcích zachyceno cévní řečiště a optický terč. Navíc se na snímcích mohou vyskytnout patologie formou retinálních lézí. Retinální léze jsou červené krvácivé skvrny, manifestující červenou barvou.



Obrázek 39: Snímek sítnice

Dataset retinálních snímků obsahoval 2797 anonymních obrazových záznamů pacientů. U 1015 snímků pacientů byly přítomny retinální léze. Tyto snímky byly použity následnou analýzu a testování navrhovaného algoritmu.

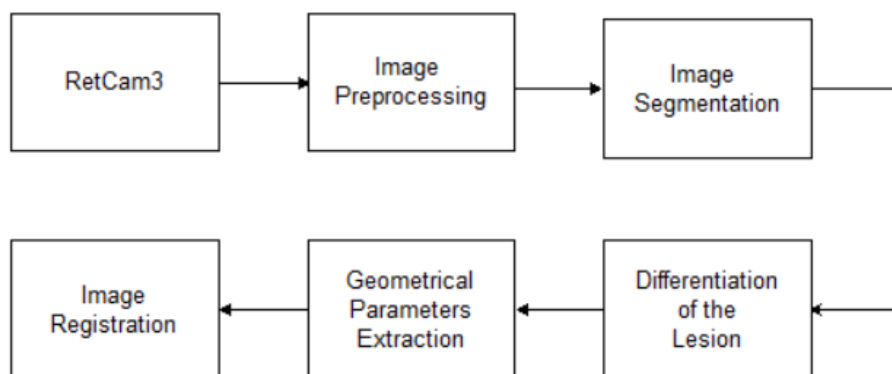


**Obrázek 40: Snímky zahrnující zastoupení retinálních lézí**

Analýza retinálních lézí je značně zkomplikována faktem, že barevné spektrum lézí je téměř identické s barevným spektrem cévního řečiště.

## 7 TEORETICKÝ NÁVRH ALGORITMU PRO ANALÝZU RETINÁLNÍCH LÉZÍ

V této kapitole je pozornost věnována teoretickému návrhu řešení algoritmu pro automatickou analýzu, modelování a časovou evaluaci retinálních lézí. Algoritmus je složen z několika procesů, které jsou prezentovány na blokovém schématu (Obrázek 41.).



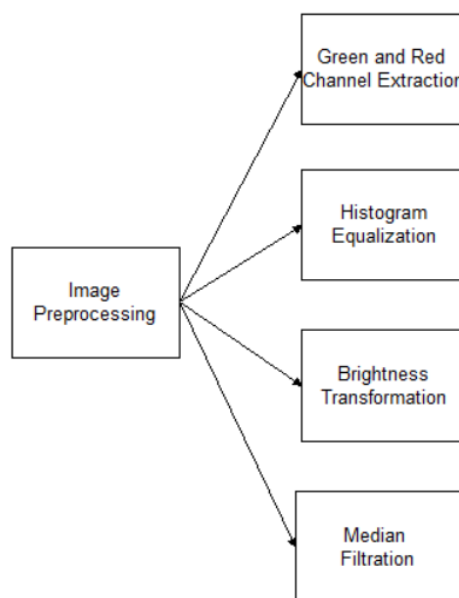
**Obrázek 41: Blokové schéma návrhu algoritmu pro analýzu retinálních lézí**

Vstupním prvkem celé analýzy je digitální snímek sítnice zaznamenaný retinální kamerou RetCam3. V první části algoritmu je snímek předzpracován. Zde dochází ke korekcím jasových a kontrastních nehomogenit snímků sítnice. Po předzpracování následuje segmentační proces aktivními konturami a následná binarizace detekované léze. V této části dochází k izolaci detekované retinální léze od pozadí. Následující kroky jsou dalším zpracováním segmentovaných lézí. Jedná se o unifikaci lézí, analýzu geometrických parametry léze pro následnou možnost srovnání v čase a registraci obrazu.

## 8 PŘEDZPRACOVÁNÍ OBRAZU

Po digitalizaci vstupního analogového signálu získáváme digitalizovaný obraz snímané scény. Po této digitalizaci je nutné provést další analýzu obrazových dat, a to z důvodu možného zkreslení např. nevhodně zvolenou technikou snímání nebo díky nevyhovujícím podmínkám během snímání.

Primárním, a tedy nezbytným krokem ve zpracování obrazu je jeho předzpracování. Tento proces je proveden za účelem dosažení co největšího zvýraznění objektů zájmu, retinálních lézí oproti pozadí. Předzpracováním obrazu je zajištěno zvýraznění hran objektů vůči pozadí a zlepšení jejich kontrastních vlastností. Vhodně zvolenými kroky předzpracování je zajištěna vyšší úspěšnost následné analýzy a segmentace retinálních lézí a přesnější extrakce geometrických parametrů. Korekce chyb obrazového signálu nám usnadňuje řada technik.



**Obrázek 42: Blokové schéma jednotlivých procesů předzpracování obrazu**

Předzpracování snímku je provedeno těmito čtyřmi metodami

- Výběh vhodné chrominační složky snímku
- Ekvalizace histogramu
- Jasové transformace
- Mediánová filtrace

## 8.1 Výběr vhodné chrominační složky retinálního snímku

Barevné RGB obrazové záznamy jsou složeny ze tří chrominačních vrstev. Jsou to červená, zelená a modrá chrominační vrstva. Z matematického hlediska se jedná o trojrozměrnou matici RGB snímku, kterou je možné rozložit na jednotlivé chrominační složky ve tvaru 2D matic. Každá chrominační složka dominuje rozdílnými vlastnostmi. Jedná se především o zvýraznění určitých objektů vůči pozadí. Zvolením vhodné kombinace nebo výběrem jednotlivé chrominační složky je docíleno vytříbení požadovaných vlastností obrazového záznamu.



Obrázek 43: Barevný RGB nativní snímek




Obrázek 44: Jednotlivé chrominační vrstvy RGB snímku

Pro kvalitní analýzu retinálních lézí je důležité zviditelnit léze oproti pozadí snímku. Zvýraznění retinálních lézí je dosaženo výběrem kombinace červené a zelené chrominační vrstvy, jelikož tato kombinace vykazovala nejlepší zřetelnost lézí a prosvětlení tmavých okrajových částí snímku pro následující analýzu. Touto operací dojde k potlačení modré chrominační složky RGB obrazového záznamu což znamená vynulování prvků 2D matice modré vrstvy.



Obrázek 45: Snímek s extrahovanou zelenou a červenou chrominační vrstvou

Dále je kombinace červené a zelené chrominační složky monochmatizována pro další zvýšení zřetelnosti retinálních lézí. Monochromatická operace je převedení barevného snímku do šedotónového spektra barev. [22] [23]




**Obrázek 46: Snímek s extrahovanými chrominačními složkami (vlevo), monochromatický snímek (vpravo)**

```
%extrakce zelené a červené ch. složky
model_RG(:,:,1)= i (:,:,1);
model_RG(:,:,2)= i (:,:,2);
model_RG(:,:,3)= zeros (r,s);%vynulování modré složky obrazu
```

**Obrázek 47: Ukázka kódu pro extrakci zelené a červené chrominační složky obrazu**

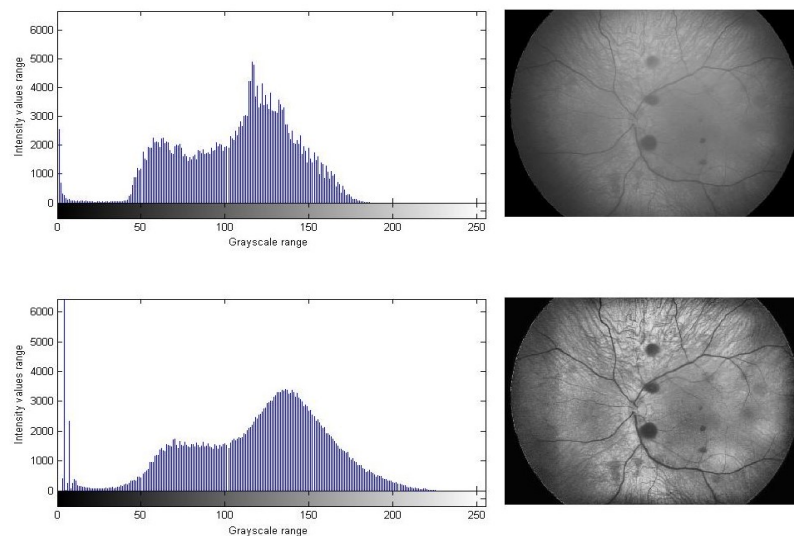
## 8.2 Ekvalizace histogramu

Histogram je důležitým ukazatelem zastoupení jednotlivých úrovní intenzit jasu všech pixelů v digitálním obraze. Každý histogram je vyjádřen vektorem, jehož složky jednotlivých intenzit jsou úměrně zastoupeny v obraze. Úpravou tvaru histogramu změníme rozložení úrovní jasu a tím měníme kontrastní vlastnosti snímku. To umožňuje zvýraznit špatně rozpoznatelné detaily s nižším kontrastem.



**Obrázek 48: Ekvalizace histogramu**

Ekvalizace histogramu zajišťuje stejnoměrné rozložení jasových úrovní tak, aby se vyskytovaly v širokém rozmezí. Pomocí metody CLAHE, tedy adaptivní ekvalizace histogramu (Contrast-Limited adaptive histogram equalization) docílíme lepších kontrastních vlastností retinálních lézí. Velkou výhodou této metody je, že je prováděna na malých lokálních oblastech snímku, oproti běžné ekvalizaci, která je provedena na celé ploše snímku najednou. Kontrast je zvyšován postupně na každé lokální oblasti. Pro každou oblast je používán individuální histogram. Sousední oblasti jsou pak spojeny bilineární interpolací, aby byly eliminovány uměle vytvořené hranice. [22] [23]



Obrázek 49: Ukázka ekvalizace histogramu

### 8.3 Jasové transformace

Pro další práci s hodnotami jasu jsou využívány jasové transformace. Zde dochází ke změně určité vstupní hodnoty jasové funkce na výstupní. Z matematického hlediska lze jasové transformace vyjádřit matematickým zápisem:

$$q = T(p). \quad (14)$$


Kde:

T-transformační funkce

p-vstupní hodnota jasu

q-nová (výstupní) hodnota jasu.

Existuje více možností přístupu k jasovým transformacím. Rozdělujeme je na globální, lokální a bodové jasové transformace. U globální jasové transformace dochází k výpočtu nové hodnoty pixelu z hodnot na celém obrazu. Principem lokální jasové transformace je vypočtení nové hodnoty z nejbližšího okolí pixelu. U bodové jasové transformace je nová hodnota vypočtena pouze z hodnoty téhož pixelu.



Obrázek 50: Rozdělení jasových transformací

U jasové transformace dochází k jasové korekci nehomogenity osvětlení a také ke korekci kontrastu. V navrženém algoritmu je jasová transformace využívána primárně ke zintenzivnění kontrastu objektů. Cílem je maximalizace zviditelnění retinálních lézí. V navrženém algoritmu je




použito bodové jasové transformace. Jedná se o změnu hodnoty jasu pro každý samostatný pixel zvlášť. [22] [23]

$$f'(x, y) \xrightarrow{T} (x, y) \forall x, y \in \Omega(I) \quad (15)$$

Kde:

$\Omega(I)$  vyznačuje doménu celého obrazu




**Obrázek 51:** (Vlevo) je snímek před jasovou transformací, (vpravo) po provedení operace jasové transformace

## 8.4 Mediánová filtrace


Posledním krokem předzpracování obrazu je mediánová filtrace. Mediánová filtrace je nelineární proces, často používaný pro odstranění šumu v snímku. Mediánový filtr je využíván za účelem snížení šumu ale zachování hran objektů v obraze.

Pro účel filtrace retinálního obrazu byla zvolena vestavěná funkce programu MATLAB. Jedná se o filtr určený pro 2D obrazové matice. Každý výsledný pixel operace obsahuje medián  $[m \ n]$  rozměrné matice umístěnou kolem vstupního pixelu. Toto je následně provedeno na každém pixelu obrazu. V analyzačním algoritmu byla použita velikost mediánového filtru 9x9 pixelů.

Mediánová filtrace pracuje na principu 2D diskretní konvoluce. Jedná se o nízkofrekvenční filtr redukující vysokofrekvenční složky signálu v obraze neboli šum. Výstupem mediánové filtrace jsou hladké kontury objektů, které předurčují plynulejší průběh aktivních kontur, jež jsou náchylné k prudkým změnám jasového spektra. [22] [25]



**Obrázek 52:** Snímek před mediánovou filtrací (vlevo) a po provedení filtrace (vpravo)

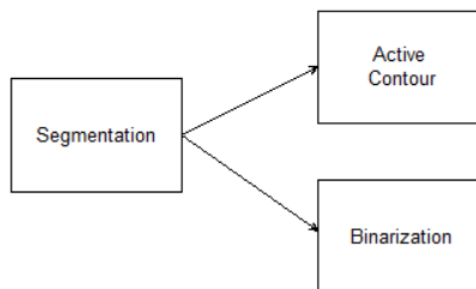


**Obrázek 53:** Ukázka mediánové filtrace na jedné retinální lézi



## 9 SEGMENTACE OBRAZU

Tato kapitola je věnována druhé části navrženého analyzačního algoritmu. Jedná se o popis použitých metod pro segmentaci obrazu. Hlavním cílem segmentace je separace pixelů zájmu od pixelů pozadí snímku. Zde je v prvním kroku využito procesu aktivních kontur, které ohraničí požadované retinální léze. Následně je použit proces binarizace, kdy dojde k úplnému oddělení pixelů lézí od pozadí pro následující metody zpracování. [23] [25]




Obrázek 54: Blokové schéma procesů segmentace obrazu

### 9.1 Aktivní kontury

Metoda aktivních kontur spadá mezi jednu z nejpokročilejších metod segmentace obrazu. Jedná se o výpočetně náročné procesy založené na principu deformace modelační křivky podle energií v obraze. Aktivní kontura je deformovatelná iterační křivka, která na základě energetických vlastností obsažených v obraze postupně deformuje svůj tvar. Deformace aktivní kontury probíhá až do doby, dokud nezíská tvar hrany námi segmentovaného objektu v rámci přednastaveného počtu iterací. Metoda aktivních kontur je využívána především pro označování zájmových objektů jak ve statických obrazech, tak u videosekvencí.

Energetická mapa snímku viz (Obrázek 55.) prezentuje zastoupení jednotlivých energií v obraze. Teplými barvami jako jsou žlutá a červená jsou v obraze zastoupeny kladné hodnoty energií. Studenými barvami manifestují záporné energie v obraze. Retinální léze nabývají záporných hodnot energie. Aktivní kontury reagují na strmou změnu energie v obraze. Modelační iterační křivka umístěna uvnitř retinální léze se šíří prostředím se zápornou energií, dokud nenarazí na prudkou změnu energie na hraně objektu. Zde dochází k zastavení deformování tvaru modelační křivky.



Obrázek 55: Energetická mapa snímku

Pro detekování retinálních lézí ze snímku sítnice byl implementován kód v MATLABu dle článku [27]. Jedná se o metodu implementace aktivních kontur bez hran, které jsou přizpůsobeny méně kvalitním snímkům, jež obsahují šum a jasovou nehomogenitu. [23] [25] [27]

### 9.1.1 Numerický postup implementace

Je zaveden nový funkcionál energií, který prezentuje rozložení intenzit jednotlivých bodů:

$$E^{LGDF} = \int_{\Omega} E_x^{LGDF} dx \int_{\Omega} (\sum_{i=1}^N -\omega(x-y) \log p_{i,x}(I(y)) dy) dx \quad (16)$$

kde  $p_{i,x}(I(y))$  je funkcí rozložení hustoty pravděpodobnosti v oblasti  $\Omega_i$ , váhovou funkci představuje člen  $\omega(x-y)$  a  $-\log p$  představuje přechod od minimalizace k požadované maximalizaci. Přítomnost dvojitého integrálu je z důvodu minimalizace funkcionálu  $E_x^{LGDF}$  pro všechny body  $x$  v obrazovém regionu  $\Omega$ .

Je předpokládáno, že obrazový region  $\Omega$  lze rozdělit na dvě samostatné oblasti, a to popředí a pozadí. Jedná se o level-setové funkce  $\phi$ . Za použití Heavisideovy funkce  $H$  lze funkci energie vyjádřit následovně:

$$\begin{aligned} & E_x^{LGDF}(\phi, u_1(x), u_2(x), \sigma_1(x)^2, \sigma_2(x)^2) \\ &= - \int \omega(x-y) \log p_{x,i}(I(y) M_1(\phi(y))) dy - \int \omega(x-y) \log p_{x,i}(I(y) M_2(\phi(y))) dy \end{aligned} \quad (17)$$

kde  $M_1(\phi(y)) = H(\phi(y))$  a  $M_2(\phi(y)) = 1 - H(\phi(y))$  a je možné funkci přepsat jako:

$$E^{LGDF}(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) = \int_{\Omega} E_x^{LGDF}(\phi, u_1(x), u_2(x), \sigma_1^2(x), \sigma_2^2(x)) dx \quad (18)$$

Aby byla evoluce kontury přesnější je nutné regularizovat level-setovou funkci, která zabraňuje odchýlení aktivní kontury od dané vzdálenosti:

$$P(\phi) = \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx \quad (19)$$

Následně je nutná regulace nulové set-level funkce omezením délky této funkce:

$$L(\phi) = \int |\nabla H(\phi(x))| dx \quad (20)$$

Celkový energetický potenciál je nyní možné přepsat takto:

$$F(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E^{LGDF}(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) + vL(\phi) + \mu P(\phi) \quad (21)$$

kde  $v, \mu > 0$  jsou váhové konstanty. Prakticky lze Heavisideovu funkci aproximovat funkcí vyhlazování, která je definovaná jako:

$$H_{\varepsilon} = \frac{1}{2} \left[ 1 + \frac{1}{2} \tan^{-1} \left( \frac{x}{\varepsilon} \right) \right] \quad (22)$$

Derivace této funkce je pak:

$$\delta_{\varepsilon} = H'_{\varepsilon}(x) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + x^2} \quad (23)$$

Aproximace energetického funkcionálu je poté následující:

$$F(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E^{LGDF}(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) + vL_{\varepsilon}(\phi) + \mu P(\phi) \quad (24)$$

A minimalizaci energetického funkcionálu řeší rovnice gradientního klesajícího toku:

$$\frac{\partial \Phi}{\partial t} = -\delta_\varepsilon(\Phi)(e_1 - e_2) + v\delta_\varepsilon(\Phi)\operatorname{div}\left(\frac{\nabla\Phi}{|\nabla\Phi|}\right) + \mu\left(\nabla^2(\Phi) - \operatorname{div}\left(\frac{\nabla\Phi}{|\nabla\Phi|}\right)\right) \quad (25)$$

kde:

$$e_1(x) = \int_{\Omega} \omega(y-x) \left[ \log(\sigma_1(y)) + \frac{(u_1(y)-I(x))^2}{2\sigma_1(y)^2} \right] dy \quad (26)$$

$$e_2(x) = \int_{\Omega} \omega(y-x) \left[ \log(\sigma_2(y)) + \frac{(u_1(y)-I(x))^2}{2\sigma_2(y)^2} \right] dy \quad (27)$$

Pro úspěšnou detekci a následnou analýzu retinálních lézí bylo nutné nastavit tyto parametry funkci:

- **n (NumIter)** – počet kroků iterace.
- **$\Delta t$  (timestep)** – časový krok posunu křivky (vyšší hodnoty parametru znamenají rychlejší posun křivky, ale větší posunové nepřesnosti).
- **$\mu$  (mu)** – konstanta zajišťující co nejmenší odchýlení křivky od své aktuální pozice během deformačního modelování.
- **$\alpha$  (alf)** – konstanta, kladoucí váhu na energii obrazu, která přitahuje křivku ke hranám během její evoluce
- **$v$  (nu)** – konstanta ovlivňující délku kontury. Nižší hodnoty konstanty znamenají možnost nabývat větší délky při deformačním modelování kontury, na druhou stranu ale znamená vyšší riziko přitažení kontury k artefaktu obrazu.
- **$c_0$  (c0)** – tímto členem jsou násobeny hodnoty pixelů nacházející se uvnitř kontury. Na vnitřní straně kontury jsou pixely násobeny hodnotou zápornou, naopak vně jsou hodnoty multiplikovány hodnotou kladnou. Vyšší hodnota znamená rychlejší počáteční pohyb inicializační kontury.
- **$\varepsilon$  (epsilon)** – tato hodnota udává šířku Diracova impulsu, který zajišťuje rychlejší pohyb počáteční inicializační křivky. Vyšší hodnoty značí méně přesné výsledné vymodelování kontury.
- **$\sigma$  (sigma)** – je parametrem Kernelovy funkce, která částečně kompenzuje nehomogenitu jasové domény snímku. Čím vyšší hodnoty konstanta dosahuje, tím více se křivka aktivní kontury při své modelaci vzdaluje od své aktuální pozice během jednoho iteračního kroku.
- **$\lambda_1$  (lambda1)** – parametr, jímž je násobena funkce  $e_1(x)$  a tím je přikládána váha oblasti uvnitř kontury během modelace křivky
- **$\lambda_2$  (lambda2)** – parametr, jímž je násobena funkce  $e_2(x)$  a tím je přikládána váha oblasti vně kontury během modelace křivky


U parametrů  $\lambda_1$  a  $\lambda_2$  záleží nejen na jejich vlastní hodnotě, ale také na poměru mezi oběma parametry. Pokud je poměr mezi konstantami  $\lambda_1 > \lambda_2$  má modelační křivka tendenci se smršťovat. V opačném případě poměru mezi parametry dochází k expandaci modelační křivky.

V závorkách jsou uvedeny názvy parametrů obsažené v příloženém kódu. [27]


### 9.1.2 Inicializační kontura a její umístění

Za inicializační konturu lze použít jakoukoliv křivku uzavřeného tvaru. V případě retinálních lézí je známo, že většina nabývá kruhovitěho charakteru a z toho důvodu je inicializační křivka

definována jako kružnice o určitém poloměru. Umístění křivky je provedeno kliknutím kurzorem na požadovanou pozici uvnitř kontury. Po umístění inicializační křivky aktivní kontury dojde k zahájení modelování aktivní kontury expandováním kontury směrem vně k hranám detekovaného objektu po zvolených iteračních krocích. Je důležité snažit se o umístění kontury co nejpřesněji na střed. To zajišťuje následné přesnější modelování kontury. [25] [27]



**Obrázek 56: Deformace křivky aktivní kontury v rámci 300 iterací**




**Obrázek 57: Tři detekované léze na retinálním snímku**

## 9.2 Binarizace

Druhou částí segmentačního procesu je binarizace. Proces binarizace je aplikován na snímek s výslednou detekovanou konturou retinální léze. Touto metodou dojde k separaci pixelů zájmu a pixelů pozadí do dvou samostatných skupin. Těmto oddílům pixelů je pak přidělena nová jasová hodnota, jednoznačně klasifikující manifestaci retinální léze a obrazové pozadí.

Hodnoty jasu jsou pixelům obrazu přiděleny na základě energetické mapy, ze které je známo, že retinální léze, tedy oblasti nacházející se uvnitř kontury nabývají záporných hodnot oproti pixelům oblasti vně kontury, které dosahují hodnot kladných.



**Obrázek 58: Proces binarizace jedné léze, zleva: nativní monochromatická data, segmentace léze na bázi aktivních kontur (xy iterací), energetická mapa aktivních kontur a výsledný binární model na základě prahování energetické mapy.**


Následně je jednoduchým cyklem skenován každý pixel obrazu. Dle hodnoty, které pixely nabývají v energetické mapě jsou rozděleny do dvou samostatných tříd, kterým je následně přiřazena nová hodnota jasu, tedy hodnota 0 nebo 1. Pixely s přiřazenou hodnotou 1 jsou pixely oblasti zájmu, tedy retinální léze a nabývají barvu bílou. Pixelům pozadí je přidělena hodnota 0, tedy barva černá.

```
%binarizace
[r s]=size(phi); %zjištění počtu řádků a sloupců snímku

for i=1:r
    for j=1:s
        if phi(i,j)<0 %řádky a sloupce se zápornou hodnotou
            bin(i,j)=1;%přidělení hodnoty 1
        else
            bin(i,j)=0; %přidělení hodnoty 0
        end
    end
end
end
```


**Obrázek 59: Ukázka kódu pro binarizaci obrazu**

Takto je možné vytvořit segmentační model retinální léze. Stejným způsobem dochází k segmentaci i v případě, že se na snímku vyskytuje více retinálních lézí.



**Obrázek 60: Snímek s detekovanými konturami (vlevo), binarizovaný snímek (vpravo)**

Pokud je na snímku přítomná více než jedna léze, je každá segmentovaná léze uložena do separované proměnné, tedy je vytvořen nový samostatný obraz. Aby výsledné léze byly hodnotitelné stejně jako na původním obraze, je nezbytným krokem následně všechny léze sloučit do jednoho snímku. [22] [23]



**Obrázek 61: Proces vytvoření binárního segmentačního modelu více retinálních lézí**

## 10 DIFERENCIACE RETINÁLNÍCH LÉZÍ

Tato kapitola se zabývá algoritmem pro diferenciaci jednotlivých retinálních lézí. Cílem algoritmu diferenciaci lézí je přehledné rozlišení jednotlivých retinálních lézí na snímcích disponujících více lézemi a umožnění přehlednějšího sledování vývoje retinálních lézí v čase. Diferenciaci retinálních lézí je možné provést po vytvoření segmentačního modelu léze.

### 10.1 Image labeling

Pro tyto účely bylo využito image labellingu. Principem image labellingu je přiřazení binárnímu modelu retinální léze unikátní klasifikační třídy. Předpokladem pro správné rozlišení objektů v obraze je binární podoba obrazového záznamu. To znamená, že pixely objektů zájmu nabývají všechny stejné nastavené hodnoty, ovšem odlišné od hodnot pixelů pozadí. Další nezbytnou vlastností pro použití image labellingu je diskontinuita objektů v obraze. Pokud by došlo k překrývání dvou objektů v obraze, byly by tyto dva objekty klasifikovány do jedné unikátní třídy. Pomocí image labellingu dojde k přehledné diferenciaci jednotlivých lézí barvou, nebo jejich očíslováním, jak je možné vidět na přiloženém obrázku pod textem.

Matematicky princip image labellingu spočívá ve skenování všech pixelů binárního modelu obrazu a zjišťování jejich hodnoty. Je zaveden operátor skenování  $V$ . Skenovací proces prochází pixely po řadách a hledá pixel u něhož je hodnota  $V = 1$ , což znamená, že pixel v binárním modelu nabývá hodnoty 1. Takto nalezený pixel je označen a jsou prohledávány nejbližší čtyři sousední pixely. Pokud sousední pixel nebo pixely nabývají stejné hodnoty, je jim přiřazeno totožné označení a je uvažována jejich rovnocennost. Takto jsou prohledány všechny pixely obrazu. Následně je provedeno druhé skenování, kdy dochází k unikátnímu klasifikování označených tříd pixelů. [22] [29]



Obrázek 62: Nativní snímek (vlevo), ohraničené léze aktivními konturami (vpravo)



Obrázek 63: Klasifikace lézí pomocí image labeling

## 11 ANALÝZA GEOMETRICKÝCH PARAMETRŮ RETINÁLNÍCH LÉZÍ

Tato kapitola je zaměřena na předposlední blok analyzačního algoritmu. Jedná se o část pro extrakci geometrických parametrů retinálních lézí. K hodnocení retinálních lézí je důležité znát jejich geometrická kritéria. Zejména pro hodnocení lézí v čase je důležité znát její velikost u prvotního záznamu a mít možnost porovnání velikosti stejné léze na obrazovém záznamu provedeném po určitém časovém intervalu.

Parametry velikosti retinální léze se vztahují k velikosti plochy optického disku, jedná se o tzv. papilla diameter. Z technického hlediska neodpovídá velikost retinální léze na obrazovém záznamu skutečným rozměrům, které nabývá léze na sítnici. Proto je zvoleno prezentování veškerých výsledků extrakce geometrických parametrů v obrazové jednotce pixel.

Pro hodnocení retinální léze je ze segmentačního modelu zjištěná hodnota plochy a poloměru retinální léze. To je zajištěno jednoduchými matematickými operacemi. V první části dochází ke zjištění celkové velikosti segmentovaného snímku, a to prozkoumáním 2D matice binárního obrazu. V druhém kroku dochází ke kontrole veškerých pixelů snímku cyklickou operací. Cílem cyklu je vyhledání veškerých bílých pixelů, tedy pixelů nesoucích hodnotu 1. Jakmile algoritmus zaznamená přítomnost pixelů s hodnotou jedna, zapíše jej do vektoru *pl*. Takto cyklus projde všechny hodnoty 2D matice. Výsledkem je plocha retinální léze, která je součtem všech zapsaných členů vektoru *pl* v pixelech.

```
%%plocha léze
[r s]=size(bin);
l=1;
for ii=1:r
    for jj=1:s
        if bin(ii,jj)==1
            pl(l)=bin(ii,jj);
            l=l+1;
        end
    end
end

plocha_leze=length(pl)
%poloměr vypočítaný z plochy léze
r=round((sqrt(plocha_leze/pi)))
```

Obrázek 64: Ukázka kódu v MATLABu pro zjištění plochy a poloměru retinální léze

Vzhledem k tomu, že většina retinálních lézí má kruhovitý charakter, můžeme na základě této znalosti vypočítat jejich průměr. Za pomoci známých matematických vztahů pro výpočet plochy a poloměru kružnice, je algoritmem stanoven poloměr léze v pixelech. [28]

$$S = \pi \cdot r^2 \quad (28)$$

$$r = \sqrt{\frac{S}{\pi}} \quad (29)$$

S – plocha optického terče v pixelech

r – poloměr optického terče v pixelech




## 12 NÁVRH ALGORITMU REGISTRACE OBRAZU

Algoritmus pro registraci obrazu má za cíl unifikaci polohy retinální léze. Algoritmus je využíván při hodnocení dvou obrazových záznamů získaných v časovém odstupu, tedy dvou retinálních snímků téhož pacienta pořízených po určitém časovém intervalu. Vlivem časového odstupu pořizování retinálních záznamů může docházet ke geometrické modifikaci retinální léze. V případě snímků sítnice dětí jsou tyto odlišnosti způsobené především neovlivnitelnou polohou oka pacienta, vznikají ovšem také rozdílným náklonem nebo pootočením ruční kamery RetCam3. K transformaci může také dojít vlivem rozdílného tlaku kamery na rohovku vyšetřovaného pacienta. Z těchto důvodů je pro následné přesnější hodnocení retinálních lézí nutné unifikovat jejich pozici vůči referenčnímu snímku. [25]

### 12.1 Registrace obrazu

V této kapitole jsou popsány obecné postupy registrace obrazu. Registrace obrazu určuje míru transformace obrazu vůči referenčnímu snímku a umožňuje obraz zrekonstruovat tak, aby odpovídal snímku referenčnímu. Snímek dříve pořízený se v této metodě stává snímkem referenčním. Tato část analyzačního algoritmu slouží pro následující přesnější stanovení parametrů retinálních lézí a vývoje onemocnění ROP.



Obrázek 65: Proces metody registrace obrazu

K nejznámější metodě registrace obrazu patří fázová korelace. Ta je založena na výpočtu Fourierovou transformací a jejím cílem je získání posuvu mezi dvěma částečně se překrývajícími obrazy. Křížové výkonové spektrum fázové korelace má vrchol v místě posuvu mezi obrazy.

Metody registrace obrazu se dělí podle různých hledisek a je možné je klasifikovat podle možných kritérií:

- **Dimenze** – Metody registrace obrazu můžeme rozdělit na časové, kdy jsou zpracovávány snímky pořízené s časovými rozestupy a je sledován stav a vývoj určitého jevu v čase. Druhou možností je rozdělení podle dimenze prostoru referenčního obrazu se srovnávaným obrazem (2D/2D, 2D/3D, 3D/3D).
- **Oblasti lokální a globální transformace** – Zde je rozdíl ve velikosti části obrazu, na němž je proces registrace aplikován. U globální transformace je registrace obrazu aplikována na obraz jako celek, kdežto u lokální registrace je pro každou část obrazu aplikován jiný typ transformace o různých parametrech.
- **Typu transformace**
  - Rigidní – Neboli tuhá transformace. Zde spadá translace a rotace obrazu.

- Afinní – Tato transformace mění měřítko obrazu a zachovává rovnoběžný typ čar.
- Projektivní – Rovnoběžnost čar není zachována, zůstává pouze rovnost čar.
- Elastická – Také označována jako pružná, deformační nebo nelineární transformace. U tohoto typu transformace může dojít k jakékoliv deformaci obrazu, ale ve většině případů se jedná o deformace ne příliš vysokých řádů.
- **Automatická vs. Interakční** – Metody registrace mohou být rozděleny na automatické, semi-automatické a manuální. U manuálních metod je registrace prováděna celá uživatelem. U semi-automatické metody je určitá část kroků registrace prováděna automaticky, ale výsledek je ověřen uživatelem. U plně automatických metod nedochází k žádné interakci s uživatelem a veškeré kroky registrace jsou prováděny automaticky.
- **Domény** – Registrační proces může probíhat v prostorové nebo frekvenční doméně. U prostorové domény jsou hledány intenzity nebo příznaky v obraze. Registrační metody využívající frekvenční doménu nacházejí parametry pro práci v doméně prostorové.
- **Modality** – Zde jsou metody členěny na multimodální a monomodální. Mezi monomodální metody spadají všechny obrazy, které byly pořízeny stejnou metodou. U multimodálních metod dochází k porovnávání snímků, u kterých došlo k pořízení různými modalitami (různé přístroje a fyzikální principy). Více rozšířené jsou metody multimodální, jelikož obsahují více detailnějších informací a lze jednodušeji určit bod zájmu. [25]

## 12.2 Registrace retinálních obrazů

Součástí segmentačního algoritmu je návrh doplňkové modality registrace obrazu pro unifikaci pozice retinální léze. Ta je zajištěna pomocí translace pixelů obrazu. Princip registrace retinálních snímků spočívá ze zjištění souřadnic těžiště referenční léze na referenčním snímku. Za referenční obraz je považován ten, jenž je pořízen při prvním vyšetření pacienta. Zjištěním souřadnic retinální léze na později pořízeném snímku a jejich porovnáním s referencí, zjistíme posun vůči referenci.

$$C = [x, y] \rightarrow C^*[x', y'] \quad (30)$$

$C$  – Těžiště referenční léze

$x, y$  – souřadnice těžiště v obraze

$C^*$  – Těžiště léze později pořízeného snímku

$x', y'$  – Souřadnice těžiště retinální léze později pořízeného snímku

Pomocí translace pixelů dojde k posunu všech pixelů v obraze o zjištěnou hodnotu rozdílu mezi referenčním těžištěm a registrovaným těžištěm. Nová hodnota těžiště retinální léze má v 2D prostoru souřadnice totožné s referenčním těžištěm léze.


## 13 TESTOVÁNÍ A HODNOCENÍ PARAMETRŮ ALGORITMU NA REÁLNÝCH PACIENTSKÝCH DATECH

Koncovou částí zadání diplomové práce je testování navrženého analyzačního algoritmu na reálných patientských datech. V této kapitole jsou popsány postupy testování navržených postupů segmentace retinálních lézí. Testování zahrnuje také prezentaci závislosti nastavení důležitých parametrů používaných metod a jsou zde zhodnoceny jejich výsledky. V následujících podkapitolách jsou zpracovány nejdůležitější operace a modifikace, které mají vliv na kvalitu výsledné detekce retinální léze.

### 13.1 Vliv předzpracování obrazu na následnou detekci retinálních lézí

V této podkapitole je zaznamenána důležitost předzpracování obrazu na segmentaci retinálních lézí. Během předzpracování dochází ke korekci jasových nehomogenit snímku, ale hlavně ke zvýšení kontrastu a tím zvýraznění původně špatně viditelných objektů zájmu snímku.


Na přiložených snímcích je jasné vidět, že při vynechání předzpracování obrazu dochází při převedení na monochromatické spektrum barev k potlačení některých méně kontrastních lézí, které jsou na předzpracovaném snímku dostatečně kontrastní pro následnou detekci



**Obrázek 66: Vliv předzpracování obrazu na viditelnost léze. Vlevo nativní snímky, vpravo snímky po předzpracování obrazu**

Pro úspěšné ohraničení retinální léze je důležitá kvalitní zřetelnost jejich hran. Na nativních snímcích nejsou hrany léze tak kontrastní jako u předzpracovaných snímků. Na základě tohoto

problému dochází u nativních snímků k rozšíření aktivní kontury na další nepotřebné objekty v obraze jako jsou například cévy a tím jsou vytvořeny artefakty, které by dále byly falešně segmentovány jako retinální léze.



Obrázek 67: Výsledné detekované léze (vlevo) nativní snímek, (vpravo) snímek po preprocessingu



Obrázek 68: Druhý příklad důležitosti předzpracování obrazu. Detekované léze na nativních datech (vlevo), předzpracovaný snímek (vpravo)

## 13.2 Parametry aktivních kontur

Podkapitola testování parametrů aktivních kontur se zabývá nastavením parametrů aktivních kontur a vlivu tohoto nastavení na výslednou detekci retinální léze. U procesu aktivních kontur se pracuje s několika základními veličinami, které je nutné optimálně nastavit pro dosažení kvalitních výsledků modelace deformační křivky. Mezi tyto parametry se řadí počet iterací, poloměr inicializační kružnice a délka časového kroku. Všechny tyto parametry mají stěžejní vliv na výslednou modelaci deformační křivky aktivní kontury.

### 13.2.1 Počet iterací


Tímto parametrem udáváme, kolikrát deformační křivka během modelování změní svůj tvar. Špatným nastavením počtu iterací dochází k nechtěnému chování deformační křivky a zkreslení výsledku detekce léze. Na obrázku (a) je možné vidět, že při předimenzování parametru, počet iterací bylo nastaveno na hodnotu 300, dochází k rozšíření kontury během vykreslování na přilehlou cévu sítnice. Nedostatečným nastavením hodnoty iterací, nastavená hodnota 50 iterací, deformační křivka nestihne aproximovat hrany léze a ohraničí tak menší část léze. To je zaznamenáno na obrázku (b). Obrázek (c) prezentuje optimální nastavení počtu iterací, kdy dojde ke kvalitnímu ohraničení retinální

léze, a křivka není rozšířená na blízké cévy sítnice. Počet iterací má také vliv na celkovou výpočetní délku, jelikož zde platí, že čím vyšší počet iterací, tím vyšší časová náročnost modelace aktivní kontury.

**Tabulka 4: Tabulka časů modelace aktivní kontury pro různé počty iterací**

Počet iterací	Délka času modelování léze (s)			Celkový čas (s)
	Léze 1.	Léze 2.	Léze 3.	
300	20,63	20,44	20,23	61,3
50	4,63	4,39	4,36	13,38
150	14,17	12,88	12,98	40,03


Z tabulky je jasné, že nejrychleji vymodelovaná kontura je pro 50 iterací. Naopak nejdéle se modeluje křivka při nastavení 300 iterací.



**Obrázek 69: Vliv počtu iterací na modelování kontury. (a) předimenzováno – 300 iterací, (b) poddimenzováno – 50 iterací, (c) optimální nastavení – 150 iterací**

### 13.2.2 Velikost inicializační kružnice


Velikost inicializační kružnice udává inicializační poloměr deformační křivky. Následně je křivka aproximována směrem k hranám objektu. Velikostí inicializační kružnice značně ovlivníme výslednou spolehlivost detekce retinální léze. Testováním bylo prokázáno, že pro kvalitnější výsledek segmentace retinální léze je dobré zvolit inicializační kružnici o poloměru menším, než je poloměr léze. Křivka se tak aproximuje v homogenním prostředí směrem k hranám léze a nedochází k zachytávání křivky o artefakty v obraze. Zvolením příliš malého poloměru způsobí nedostatečné ohraničení retinální léze, naopak vyšší hodnota poloměru zapříčiní to, že se křivka nedostane k hranám léze a zároveň se zachytává o falešné objekty nacházející se v obdobném barevném spektru v obraze nebo přilíná k cévám sítnice.



**Obrázek 70:** Výsledné detekované léze v závislosti na zvolení poloměru inicializační kontury při počtu 150 iterací. (a) předimenzováno  $r = 10$ , (b) poddimenzováno  $r = 2$ , (c) optimální nastavení  $r = 5$

### 13.2.3 Délka časového kroku

Parametr časového kroku udává časový posun křivky. Prakticky to znamená o kolik se posune křivka během jednoho kroku. Vyšší hodnoty znamenají rychlejší posun křivky, ale větší posunové nepřesnosti. Křivka má tendenci rozšiřování i na artefakty v obraze a tím ohraničuje objekty, které jsou dále považovány za falešné retinální léze. Menší hodnota časového kroku zapříčiňuje velmi malé deformace během modelace. Na základě této skutečnosti nedojde k dostatečné aproximaci hrany retinální léze.




**Obrázek 71:** Výsledné detekované léze v závislosti na zvolení délky časového kroku při počtu 150 iterací. (a) předimenzováno – timestep = 0.5, (b) poddimenzováno – timestep = 0.001, (c) optimální nastavení – timestep = 0.01

### 13.3 Závislost velikosti obrazu na kvalitě detekce

Velikost vstupního obrazu zásadně ovlivňuje úspěšnost analýzy retinální léze a celkový čas modelace deformační křivky. Pro úspěšné hodnocení je nutné najít kompromis mezi kvalitou obrazu a celkovou dobou trvání segmentace retinálních lézí a dostačujícím výsledkem analýzy. Při zmenšení velikosti vstupního obrazu dochází k podstatnému urychlení procesů metody analýzy lézí. Ovšem také dochází ke zhoršení kvality snímku a tím k méně kvalitním výsledkům analýzy. V následujících odstavcích jsou rozebrány jednotlivé vlivy a jejich závislosti na kvalitě detekce.

#### 13.3.1 Imresize

Funkce `imresize` zajišťuje změnu velikosti 2D matice vstupního obrazu. Změna velikosti obrazů má značný vliv na jeho kvalitu. Zmenšením obrazu dochází k redukci počtu pixelů, tedy zmenšení 2D matice snímku. Tím dojde k rychlejšímu modelování aktivní kontury k hranám retinální léze. Výsledkem je ovšem méně kvalitní hraniční kontura než u snímku původní velikosti.



Obrázek 72: Rozdíl v kvalitě snímku v závislosti na velikosti obrazu. (A) nativní snímek – originální velikost, (B) redukovaný snímek – 50 % originální velikosti, (C) redukovaný snímek – 20 % originální velikosti



Z přiložených obrázků jde vidět, že čím větší zmenšení snímku použijeme, tím větší jsou ztráty kvality obrazu. To má zásadní vliv na následnou modelaci aktivní kontury a kvalitu výsledného segmentačního modelu léze.




**Obrázek 73: Segmentační model - (vlevo) originální snímek, (vpravo) redukováný snímek**



**Obrázek 74: Detail segmentované léze - (vlevo) originální velikost, (vpravo) redukováný snímek**


Na detailu segmentačních modelů lézí je vidět, že model léze analyzovaný z originálního snímku má pravidelnější a hladší tvar hrany, nedochází k tak jasné zřetelnosti jednotlivých pixelů jako u zmenšeného snímku.

Algoritmus přizpůsobený pro zmenšený snímek nefunguje správně u originálního snímku. Při použití stejného nastavení hodnot analyzačního algoritmu nastaveného na zmenšený snímek u originálního snímku, dochází ke chybné modelaci kontury. Problém nastává především u inicializační kružnice, která má na originálním snímku nedostatečný poloměr. Nestihne se tak při stejném počtu iterací dostatečně rozšířit k hranám léze.



**Obrázek 75: Výsledná aktivní kontura při použití stejného nastavení pro zmenšený a originální snímek. (Vlevo) ohraničená léze zmenšeného snímku, (vpravo) ohraničená léze originálního snímku**

Podobný problém nastává také v případě použití nastavení hodnot pro originální snímek. Inicializační kružnice má v tomto případě poloměr přesahující velikost léze. Při stejném počtu iterací se kontura nedokáže dostatečně smrštít a ohraničit retinální lézi. Navíc v tomto případě dochází k chybnému chování aktivní kontury, kdy je modelační křivka zachytávaná o nechtěné objekty v obraze a vytváří tak artefakty.



**Obrázek 76: Výsledek modelace deformační křivky při použití nastavení pro originální velikost na zmenšeném obraze**


Výsadní roli hraje velikost obrazu na časovou komplexitu modelu aktivní kontury. U redukováného snímku dochází k výraznému zrychlení práce analyzačního algoritmu.

**Tabulka 5: Tabulka časů modelace deformační křivky pro různé velikosti obrazu**


Typ snímku	Časová komplexita deformační křivky
Originální snímek	87,76 s
Redukovaný snímek – 50 % originální velikosti	19,33 s

### 13.3.2 RoI

RoI neboli region of interest je funkce, díky které je možné na snímku manuálně selektovat pouze požadovanou oblast zájmu. Ohraničením a výběrem požadované oblasti zájmu dochází k výraznému potlačení nežádoucích jevů v obraze a tím ke kvalitnější detekci retinální léze. Ve vybraném regionu dochází především k eliminaci počtu cév sítnice, které dominují téměř identickým barevným spektrem jako retinální léze. Na druhou stranu při větším množství retinálních lézí je proces ručního výběru velmi nepraktickým a zdlouhavým.




**Obrázek 77: (vlevo) běžný snímek, (vpravo) výběr oblasti zájmu RoI**



**Obrázek 78: RoI vybrané retinální léze**


Výběrem RoI dojde ke specifikaci oblasti pouze s retinální lézí. Energetická mapa takto vybrané léze má daleko menší rozptyly energií a jednoznačnější přechod energie na hraně objektu.




**Obrázek 79: Energetická mapa ROI jedné retinální léze**

Díky tomu dojde k přesnějšímu a rychlejšímu ohraničení retinální léze deformační křivkou aktivní kontury.

Modelace křivky je v tomto případě méně výpočetně náročná, jelikož deformace křivky k hranám retinální léze probíhá na menším počtu pixelů, než je tomu u celého retinálního záznamu.



**Obrázek 80: Finální segmentace retinální léze v RoI při počtu 300 iterací**



**Obrázek 81: Segmentační model RoI retinální léze**


## 14 VÝSLEDKY TESTOVÁNÍ ALGORITMU NA REÁLNÝCH PACIENTSKÝCH DATECH

V této kapitole je řešeno testování navrženého algoritmu jako celku na reálných patientských datech. Algoritmus je optimalizován tak, aby fungoval pro vícero diferenčních lézí v rámci jednoho snímku. V kapitole jsou prezentovány a komentovány výsledky modelace retinální léze, výsledky extrakce a diferenciacie segmentačních modelů léze. Zaznamenány jsou také modelační časy pro ukázkou výpočetní náročnosti navrženého algoritmu.


### 14.1 Modelace retinální léze a diferenciacie

Na následujících přiložených obrázcích jsou zobrazeny dosažené výsledky modelace a diferenciacie retinálních lézí. Algoritmus byl testován na vícero snímcích disponujícími různorodými lézemi co do kontrastních vlastností, tak velikostních, a také na lézích nacházejících se v blízkosti cév sítnice nebo na nich přímo ležících. Zhodnoceny jsou také výpočetní časy modelace aktivních kontur uvedené v přehledných tabulkách.


Algoritmus je možné modifikovat pro detekci libovolného počtu retinálních lézí. V rámci testování bylo využito nastavení detekce sedmi lézí. Inicializací algoritmu je výběr retinálních lézí, které chce uživatel detekovat. Volba je provedena kliknutím kurzorem do požadované léze. Na polohu kliku kurzoru je umístěna inicializační kružnice deformační křivky, která je následně zcela autonomně expandována k hranám retinální léze. Je důležité umístit kliknutí na střed detekované léze. Tím je zajištěno kvalitnější následné modelování aktivní kontury.



Obrázek 82: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami




**Obrázek 83: (Vlevo) Binární segmentační model lézí, (vpravo) klasifikační model umožňující diferenciaci jednotlivých lézí.**



**Obrázek 84: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku.**

Z výsledků detekovaných lézí na snímcích výše jde vidět, že algoritmus je schopen detekovat jak kontrastní léze, tak i hůře viditelné léze. Bylo záměrem vybírat různě viditelné léze a léze nacházející se v těsné blízkosti pro náročnější otestování funkčnosti algoritmu. Součástí zhodnocení je také délka trvání modelace jednotlivých lézí. Výsledné časy modelací jsou uvedeny v tabulce pod textem. Modelační časy jsou uvedeny pro představu délky trvání modelace deformační křivky.



**Obrázek 85: Očíslované retinální léze**


**Tabulka 6: Tabulka časů modelace aktivních kontur pro jednotlivé léze, při 200 iteracích**

Č. léze	Čas modelace deformační křivky	Č. léze	Čas modelace deformační křivky
1	25,21 s	5	18,51 s
2	21,92 s	6	19,88 s
3	24,97 s	7	18,29 s
4	18,71 s	<b>Celkový čas</b>	147,49 s


Průměrná doba trvání detekce jedné léze se pohybovala okolo 20 s. Celkový čas modelace sedmi lézí byl 147,5s. Časy modelací se u většiny lézí pohybují v přibližně stejné délce. To je ovlivněno počtem iterací ale také homogenitou energie v obraze. Je-li homogenní, aktivní kontura se rychleji aproximuje k hranám retinální léze, jelikož snadno narazí na strmou změnu energie na hraně. U méně homogenní léze, to jsou léze, u kterých je barevné spektrum rozmanitější se deformační křivka aktivní kontury šíří pomaleji.

Na následujících stránkách jsou přiloženy výsledky testování jednotlivých kroků analyzačního algoritmu. Ukázky jsou uvedeny pro pět testovacích snímků.







Obrázek 86: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami




Obrázek 87: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu




Obrázek 88: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku




Obrázek 89: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami




Obrázek 90: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu




Obrázek 91: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku




Obrázek 92: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami




Obrázek 93: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu




Obrázek 94: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku



Obrázek 95: (Vlevo) předzpracovaný snímek, (vpravo) ohraničené léze aktivními konturami



Obrázek 96: (Vlevo) Binární segmentační model lézí, (vpravo) diferenciované léze v rámci klasifikačního modelu




Obrázek 97: (Vlevo) nativní vstupní snímek, (vpravo) prezentace analyzovaných lézí na nativním snímku

## 14.2 Extrakce geometrických parametrů retinálních lézí

Součástí analyzačního algoritmu je také blok pro extrakci geometrických parametrů retinálních lézí. Jeho účelem je zobrazení geometrických parametrů retinálních lézí pro možnost následného hodnocení a srovnávání vývoje léze v čase.

Hodnoty jsou vztahovány k velikosti optického disku. Vzhledem k tomu, že velikost retinálních lézí na snímku neodpovídá jejich reálné velikosti na sítnici, je nutné přistoupit k hodnocení v obrazových jednotkách pixelech.

V následujících tabulkách jsou přehledně prezentovány hodnoty geometrických parametrů lézí a jejich srovnání s velikostí optického disku. Testování algoritmu pro extrakci geometrických parametrů bylo provedeno na stejných snímcích jako modelace retinálních lézí. Přesnost výsledků extrakce geometrických parametrů retinálních lézí ovlivňuje především kvalita modelace lézí. Plocha retinální léze je ovlivněná výslednou ohraničenou oblastí aktivní konturou. Z plochy léze je pak jednoduchým matematickým vztahem vypočítán poloměr léze. Je využito předpokladu kruhového tvaru retinálních lézí, a proto jsou používány matematické vztahy pro plochu a poloměr kružnice.




Obrázek 98: Diferencované léze z testovacího snímku č. 1.

Tabulka 7: Geometrické parametry retinálních lézí ze snímku č. 1.

Léze	Poloměr	Plocha	% plochy OD	Léze	Poloměr	Plocha	% plochy OD
1	9	280	43 %	5	9	284	43 %
2	9	291	45 %	6	8	250	38 %
3	9	285	44 %	7	9	286	44 %
4	9	289	44,5 %	<b>Plocha OD</b>		651	






Obrázek 99: Diferencované léze testovacího snímku č. 2.

Tabulka 8: Geometrické parametry retinálních lézí ze snímku č. 2.

Léze	Poloměr	Plocha	% plochy OD	Léze	Poloměr	Plocha	% plochy OD
1	9	298	45 %	5	9	291	45 %
2	10	310	48 %	6	9	282	43 %
3	9	281	43 %	7	9	290	44 %
4	9	287	44 %	<b>Plocha OD</b>	650		



Obrázek 100: Diferencované léze testovacího snímku č. 3.

Tabulka 9: Geometrické parametry retinálních lézí ze snímku č. 3.


Léze	Poloměr	Plocha	% plochy OD	Léze	Poloměr	Plocha	% plochy OD
1	9	296	41 %	5	9	287	40 %
2	9	279	39 %	6	9	294	41 %
3	9	268	37 %	7	8	256	35 %
4	9	283	39 %	<b>Plocha OD</b>	721		



Obrázek 101: Diferencované léze testovacího snímku č. 4.

Tabulka 10: Geometrické parametry retinálních lézí ze snímku č. 4.

Léze	Poloměr	Plocha	Plocha léze vzhledem k OD	Léze	Poloměr	Plocha	Plocha léze vzhledem k OD
1	7	173	26 %	5	7	185	28,5 %
2	8	190	29 %	6	8	189	29 %
3	8	185	28,5 %	7	8	188	29 %
4	8	187	29 %	<b>Plocha OD</b>	<b>648</b>		



Obrázek 102: Diferencované léze testovacího snímku č. 5.

Tabulka 11: Geometrické parametry retinálních lézí ze snímku č. 5.

Léze	Poloměr	Plocha	Plocha léze vzhledem k OD	Léze	Poloměr	Plocha	Plocha léze vzhledem k OD
1	9	280	43 %	5	9	287	44 %
2	9	285	44 %	6	9	275	42 %
3	9	270	41 %	7	8	240	36 %
4	9	271	41,5 %	<b>Plocha OD</b>	<b>653</b>		



Z přiložených výsledků lze tvrdit, že většina detekovaných retinálních lézí nedosahuje 50 % plochy OD. Poloměr analyzovaných retinálních lézí se pohybuje okolo 9 pixelů.

## ZÁVĚR

Je obecně známým faktem, že počty předčasně narozených dětí mají tendenci neustálého růstu. Proto je včasná diagnostika onemocnění retinopatií nedonošených stěžejním prvkem zabránění slepoty dítěte. Pro správné diagnostikování ROP je nezbytné, aby měl lékař možnost co nejdetailnějšího prozkoumání stavu nezralé sítnice nedonošeného dítěte. Z tohoto důvodu je nutné docílit co nejlepšího a kvalitního zviditelnění zájmových patologií na snímcích sítnice oproti pozadí. Hlavním benefitem diplomové práce je diferenciací retinálních lézí a extrakce jejich geometrických parametrů. Díky tomu je možné výsledky objektivizovat, neboť tyto funkcionality poskytují zpětnou vazbu pro následující srovnávání v čase. Řešení těchto problematik bylo zadáním mé diplomové práce.

Pro návrh, vývoj a testování algoritmu jsem měla k dispozici 1015 reálných patientských snímků poskytnutých Fakultní nemocnici Ostrava, centrem pro děti s vadami zraku. Jednalo se o snímky sítnice nedonošených dětí trpících onemocněním retinopatií nedonošených pořízených systémem RetCam3.

Výsledkem diplomové práce je algoritmus pro analýzu a modelaci retinálních lézí z klinických obrazových záznamů, pořízených systémem RetCam3. Stěžejní funkcí analyzačního algoritmu je segmentace retinálních lézí, diferenciací jednotlivých lézí, extrakce geometrických parametrů, diferenciací a finální vyobrazení vyhodnocených výsledků detekce.

Prvotním procesem analýzy retinálních lézí je předzpracování obrazu. Zde dochází ke korekci jasových a kontrastních vlastností snímku, a především ke zvýraznění objektů zájmu, tedy retinálních lézí. Segmentace jednotlivých retinálních lézí probíhá na bázi autonomně deformovatelných křivek aktivních kontur. Extrakce geometrických parametrů vychází z předpokladu cirkulárního tvaru retinální léze, a proto je pro tyto účely využito jednoduchých matematických vztahů pro výpočet plochy a poloměru kružnice. Diferenciací segmentovaných retinálních lézí probíhá pomocí přidělení unikátní klasifikační třídy jednotlivým lézím.

Po návrhu proběhlo testování navrženého segmentačního algoritmu. Pro testování algoritmu byly použity snímky z poskytnutého datasetu, na kterém byly otestovány veškeré části analyzačního algoritmu. Vzhledem k faktu, že výpočetní čas analyzačního algoritmu je závislý na zvolených parametrech jednotlivých operací, byly otestovány různá nastavení parametrů. Během testování jsem se zaměřila především na docílení co nejpřesnějších výsledků analýzy retinálních lézí a dosažení co nejkratšího výpočetního času analýzy. Pro přesnější představu jsou v práci uvedeny také výpočetní doby analýzy u jednotlivých nastavení parametrů algoritmu.

V poslední kapitole práce jsou uvedeny výsledky extrakce geometrických parametrů segmentovaných retinálních lézí. Veškeré rozměrové parametry jsou uvedeny v obrazové jednotce pixel. Výsledná plocha je pak vztažena k velikosti plochy OD. Z přiložených výsledků lze tvrdit, že detekované retinální léze u analyzovaných snímků nedosahují 50 % plochy OD.

Implementace algoritmu probíhala v software MATLAB R2016b.

## SEZNAM POUŽITÉ LITERATURY

- [1] KUCHYŇKA, Pavel. Oční lékařství. Praha: Grada Publishing, a.s., 2007. ISBN 978-80-247-11638. [cit. 2015-09-10]
- [2] NAŇKA, Ondřej, Miloslava ELIŠKOVÁ a Oldřich ELIŠKA. *Přehled anatomie*. 2., dopl. a přeprac. vyd. Praha: Galén, c2009, xi, s. 311–318. ISBN 978-80-7262-612-0. [cit. 2015-08-15]
- [3] Dětské oční lékařství: Retinopatie nedonošených [online]. [cit. 2016-04-13]. Dostupné z: <http://telemedicina.med.muni.cz/pdm/detske-ocni-lekarstvi/index.php?pg=retinopatie-nedonosenyh>
- [4] ŠENKOVÁ, Kateřina. Léčba a screening retinopatie nedonošených (ROP). Brno, 2010. Disertační práce. [cit. 2015-09-08] Dostupné z: [https://is.muni.cz/th/29511/lf\\_d/phd.pdf](https://is.muni.cz/th/29511/lf_d/phd.pdf)
- [5] KRAUS, Hanuš. *Kompendium očního lékařství*. Vyd. 1. Praha: Grada, 1997. ISBN 80-716-9079-1.
- [6] TIMKOVIČ, Juraj. Screening, diagnostika a léčba retinopatie nedonošených dětí [online]. Brno, 2017 [cit. 2018-01-04]. Dostupné z: [http://is.muni.cz/th/431399/lf\\_d/](http://is.muni.cz/th/431399/lf_d/). Disertační práce. Masarykova univerzita, Lékařská fakulta. Vedoucí práce Rudolf Autrata.
- [7] URANIK, Shivani S. a V. B. MALODE. Morphology based approach for Microaneurysm detection from retinal image. *2016 International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT)*. IEEE, 2016, , 635-639. DOI: 10.1109/ICACDOT.2016.7877663. ISBN 978-1-5090-2080-5. Dostupné také z: <http://ieeexplore.ieee.org/document/7877663/>
- [8] Usher, D., Dumskyj, M., Himaga, M., Williamson, T. H., Nussey, S. and Boyce, J. (2004), Automated detection of diabetic retinopathy in digital retinal images: a tool for diabetic retinopathy screening. *Diabetic Medicine*, 21: 84–90. doi:10.1046/j.1464-5491.2003.01085.x
- [9] USHER, D., M. DUMSKYJ, M. HIMAGA, T. H. WILLIAMSON, S. NUSSEY a J. BOYCE. Automated detection of diabetic retinopathy in digital retinal images: a tool for diabetic retinopathy screening. *Diabetic Medicine* [online]. 2004, 21(1): 84-90 [cit. 2015-06-28]. DOI: 10.1046/j.1464-5491.2003.01085.x.
- [10] ZHOU, Wei, Chengdong WU, Dali CHEN, Zhenzhu WANG, Yugen YI a Wenyou DU. A novel approach for red lesions detection using superpixel multi-feature classification in color fundus images. *2017 29th Chinese Control And Decision Conference (CCDC)*. IEEE, 2017, , 6643-6648. DOI: 10.1109/CCDC.2017.7978371. ISBN 978-1-5090-4657-7. Dostupné také z: <http://ieeexplore.ieee.org/document/7978371/>
- [11] SATHANANTHAVATHI, V., G. INDUMATHI, R. RAJALAKSHMI, Zhenzhu WANG, Yugen YI a Wenyou DU. Abnormalities detection in retinal fundus images. *2017 International Conference on Inventive Communication and Computational Technologies (ICICCT)*. IEEE, 2017, , 89-93. DOI: 10.1109/ICICCT.2017.7975165. ISBN 978-1-5090-5297-4. Dostupné také z: <http://ieeexplore.ieee.org/document/7975165/>
- [12] KAUR, Navkiran, Jasmeen KAUR, Mausumi ACCHARYA, Sheifali GUPTA, Yugen YI a Wenyou DU. Automated detection of red lesions in the presence of blood vessels in retinal fundus images using morphological operations. *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*. IEEE, 2016, , 1-4. DOI: 10.1109/ICPEICES.2016.7853561. ISBN 978-1-4673-8587-9. Dostupné také z: <http://ieeexplore.ieee.org/document/7853561/>

- [13] SRIVASTAVA, Ruchir, Damon W. K. WONG, Mausumi LIXIN DUAN, Sheifali JIANG LIU, Yugen TIEN YIN WONG a Wenyong DU. Red lesion detection in retinal fundus images using Frangi-based filters. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 2015, , 5663-5666. DOI: 10.1109/EMBC.2015.7319677. ISBN 978-1-4244-9271-8. Dostupné také z: <http://ieeexplore.ieee.org/document/7319677/>
- [14] Stavba oka. Encyklopedie fyziky [online]. Praha: Jaroslav Reichl and Martin Všeticka, 2006, 2015 [cit. 2015-11-12]. Dostupné z: <http://fyzika.jreichl.com/main/article/view/486-stavba-oka>
- [15] Skolajecna.cz: biologie [online]. [cit. 2016-04-13]. Dostupné z: <http://skolajecna.cz/biologie/Images/Textbook/Big/0110000/00287.jpg>
- [16] Warren retina associates. In: *Warren retina associates* [online]. 2018 [cit. 2018-04-14]. Dostupné z: <https://warrenretina.com/diseases-of-the-retina/>
- [17] Neuro-orbital ultrasound. In: *Neupsy Key* [online]. [cit. 2018-04-14]. Dostupné z: <https://neupsykey.com/neuro-orbital-ultrasound/>
- [18] JEFFERS, An L. a Canadian Paediatric Society. Retinopathy of prematurity: An update on screening and management. In: *Canadian paediatric* [online]. 2016, Mar 7 2016 [cit. 2018-04-14]. Dostupné z: <https://www.cps.ca/en/documents/position/retinopathy-of-prematurity-screening>
- [19] Sasilik: *retinopathy of prematurity* [online]. [cit. 2016-04-13]. Dostupné z: <http://www.sasilik.com.tr/en/makaleler/9-retinopathy-of-prematurity->
- [20] IMsystems [online]. [cit. 2016-04-18]. Dostupné z: <http://intelmed.ru/catalog/oft/oftalmodiagnostika/pediatricheskie-retinalnye-kamery/retcam3/>
- [21] Cmi: *Medical technology* [online]. [cit. 2016-04-18]. Dostupné z: <http://www.cmi.sk/oftalmologie/diagnostika-1/zobrazovaci-systemy/digitalni-oftalmoskopy/neprimy-oftalmoskop-omega-200>
- [22] GONZALEZ, Rafael C, Richard E WOODS a Steven L EDDINS. *Digital Image processing using MATLAB*. 2nd ed. S.l.: Gatesmark Publishing, c2009. ISBN 978-0-9820854-0-0.
- [23] KUBÍČEK, Jan. *Zpracování medicínských obrazových dat*. Vysoká škola báňská - Technická univerzita Ostrava, 2013. [cit. 2016-03-15].
- [24] HÁJOVSKÝ, Radovan, Radka PUSTKOVÁ a František KUTÁLEK. *Zpracování obrazu v měřicí a řídicí technice*. Vyd. 1. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2012. [online] [cit. 2016-03-15]. ISBN 978-80-248-2596-0. Dostupné z: <http://www.person.vsb.cz/archivcd/FEI/ZOMRT/Zpracovani%20obrazu%20v%20merici%20a%20ridici%20technice.pdf>
- [25] LIČEV, Lačezar. *Systém FOTOMng: architektura, funkce a použití*. Praha: BEN - technická literatura, 2015. ISBN 978-80-7300-521-4.
- [26] CLARITY MEDICAL SYSTEMS, *RETCAM 3 – Pediatric eye imaging*. 2014. Pleasanton CA USA [online] [cit. 2015-07-08] Dostupné z: [http://www.claritymsi.com/international/downloads/RC3Brochure\\_2013.pdf](http://www.claritymsi.com/international/downloads/RC3Brochure_2013.pdf)
- [27] WANG, Li, et al. Active contours driven by local Gaussian distribution fitting energy. *Signal Processing*, 2009, 89.12: 2435-2447.
- [28] KOVÁŘOVÁ, Veronika. *Algoritmus pro automatickou obrazovou detekci sítnicových lézí* [online]. Ostrava, 2016 [cit. 2018-04-14]. Dostupné z: <http://hdl.handle.net/10084/116258>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.

[29] FISHER, R., S. PERKINS, A WALKER a E. WOLFART. Connected Components Labeling. In: *Image Processing Learning Resources*[online]. 2003 [cit. 2018-04-19]. Dostupné z: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/label.htm>

## **SEZNAM PŘÍLOH**

Příloha I.

Obsah CD

## **Příloha I   Obsah CD**

- Diplomová práce
- Algoritmus pro analýzu, modelaci a časovou evaluaci síťnicových lézí